

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET



DIPLOMSKI RAD

VIŠEKRITERIJALNO ODLUČIVANJE I
PROCJENA EFIKASNOSTI BANAKA

Mentor:

Prof. dr. sc. Zoran Babić

Student:

Anita Marasović, univ. bacc. oec.

Split, rujan, 2018.

SADRŽAJ

1. UVOD.....	4
1.1. Problem istraživanja	4
1.2. Predmet istraživanja	7
1.3. Ciljevi i svrha istraživanja	7
1.4. Metodologija istraživanja	8
1.5. Doprinos istraživanja.....	9
1.6. Struktura rada	10
2. OPĆENITO O BANKAMA	11
2.1. Pojam i uloga banke	11
2.2. BANKOVNI POSLOVI.....	12
2.2.1. Aktivni ili kreditni poslovi	12
2.2.2. Pasivni ili mobilizacijski poslovi	13
2.2.3. Neutralni poslovi	14
2.2.4. Vlastiti bankovni poslovi	15
2.3. BANKOVNI RIZICI	16
2.3.1. Rizik likvidnosti	16
2.3.2. Kreditni rizik	18
2.3.3. Rizik kamatne stope	19
3. ANALIZA POKAZATELJA USPJEŠNOSTI POSLOVANJA BANKE	21
3.1. TEMELJNI FINACIJSKI IZVJEŠTAJI.....	22
3.1.1. Bilanca.....	22
3.1.2. Račun dobiti i gubitka	23
3.1.3. Izvještaj o novčanom toku.....	25
3.1.4. Izvještaj o promjeni kapitala	25
3.1.5. Bilješke uz finacijske izvještaje	25
3.2. FINACIJSKI POKAZATELJI ZA BANKE	26

3.2.1.	POKAZATELJI ODNOSA U BILANCI BANKE	26
3.2.2.	POKAZATELJI ODNOSA U RAČUNU DOBITI I GUBITKA	28
3.2.3.	POKAZATELJI PROFITABILNOSTI.....	30
3.2.4.	POKAZATELJI INVESTIRANJA	31
4.	TEORIJSKE POSTAVKE VIŠEKRITERIJALNOG ODLUČIVANJA.....	33
4.1.	Procjena važnosti kriterija	33
4.1.1.	Metoda svojstvenog vektora.....	34
4.2.	Metoda jednostavnog zbrajanja težina – SAW.....	36
4.3.	TOPSIS metoda	37
4.4.	PROMETHEE metoda	39
5.	PRIMJENA METODA VIŠEKRITERIJALNOG ODLUČIVANJA NA PROBLEM PROCJENE EFIKASNOSTI BANAKA.....	46
1.1.	Odabir alternativa i kriterija	46
1.2.	Određivanje težina kriterija primjenom metode svojstvenog vektora.....	49
1.3.	Rangiranje banaka TOPSIS metodom	53
1.4.	Rangiranje banaka metodom jednostavnog zbrajanja težina – SAW.....	59
1.5.	Rangiranje banaka PROMETHEE metodom	62
4.5.	Komparacija rezultata dobivenih metodama višekriterijalnog odlučivanja	68
6.	ZAKLJUČAK	69
	LITERATURA.....	71

1. UVOD

1.1. Problem istraživanja

„Banke su financijske institucije koje se bave prikupljanjem sredstava, plasiranjem sredstava te pružanjem usluga.“¹ Djeluju kao financijski posrednici pri usmjeravanju sredstava između kreditora i dužnika. Razvijene financijske institucije i tržišta predstavljaju odraz gospodarskog rasta neke zemlje. Bankama se pripisuje sposobnost mobilizacije i alokacije slobodnih novčanih sredstava te njihovo usmjeravanje u proces reprodukcije, poticanja rasta i razvoja te stvaranju novca. Može se zaključiti da imaju važnu ulogu u efikasnom poslovanju financijskog sustava, te društvenom i gospodarskom razvoju.²

Na koncu 2017. godine u Hrvatskoj su poslovale 24 banke, koje djeluju pod nadzorom Hrvatske narodne banke, s ciljem očuvanja financijske stabilnosti. Stabilnost financijskog sektora očituje se u nesmetanom odvijanju financijskog sustava i otpornosti na nenadane šokove, te predstavlja temelj održivog gospodarskog rasta. Poslovna kolebanja poput nelikvidnosti financijskih subjekata ili poteškoća u sustavu plaćanja, mogu narušiti financijsku stabilnost te poremetiti normalnu funkciju financijskog sustava. Glavni zadatak Hrvatske narodne banke je pridonošenje stabilnosti financijskog sustava, stoga analizira i sprječava pojavu sistemskih rizika, te nadzire i regulira banke, koje su glavni dio financijskog sustava.³

Banke, kao dionička društva, ciljem se ne razlikuju mnogo od ostalih poslovnih subjekata. Posluju s tendencijom ostvarivanja profita, uz što manji rizik. Ostvaruju dobit transformacijom imovine, odnosno prodaju pasivu (depozitni novac, oročeni depoziti) koja ima određena obilježja rizika, likvidnosti, iznosa i povrata, da bi od zarade kupile aktivu (vrijednosni papiri, krediti) sa drugim obilježjima. Glavni instrument kojim banke ostvaruju najveći dio svojih profita je odobrenje kredita. Krediti su manje likvidni jer ih nije moguće pretvoriti prije roka dospelosti. Kapital, koji se ostvaruje prodajom novih dionica ili zadržavanjem dobiti, štiti banku od nesolventnosti, odnosno smanjenja njene aktive.⁴

¹ Gregurek, M., Vidaković, N. (2013.): Bankarsko poslovanje, drugo izdanje, Visoko učilište EFACTUS, Zagreb, str. 9

² Ercegovac, R. (2016.): Teorija i praksa bankovnog menadžmenta, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 3

³ Hrvatska narodna banka: <https://www.hnb.hr/> [2.6.2018.]

⁴ Mishkin, F., Eakins, S.G. (2005.): Financijska tržišta + institucije, IV izdanje, Mate, Zagreb, str. 401-406

Zbog sve većeg utjecaja globalizacije i razvoja novih tehnologija financijske institucije prisiljene su često analizirati načine poslovanja kako bi opstale na tržištu. S obzirom da posluju u dinamičnom i neizvjesnom okruženju, trebaju brzo donositi odluke i reagirati na promjene iz okoline. Da bi postigle učinkovitost i konkurentsku prednost, moraju se prilagođavati potrebama klijenata i novim zahtjevima tržišta. Zbog takvih uvjeta, često se nalaze pod pritiskom kako efikasnije poslovati. Efikasnost se može definirati kao sposobnost ostvarenja ciljeva, te ukazuje na stupanj ostvarenih performansi poslovnog subjekta, a mjeri se odnosom outputa i inputa.⁵

Učinkovitost poslovanja određuje se na temelju financijskih pokazatelja, analizom financijskih izvještaja banaka. Temeljni financijski izvještaji su: bilanca, račun dobiti i gubitka, izvještaj o novčanom toku, bilješke uz financijske izvještaje i izvještaj o promjeni glavnice.⁶ Jedna od čestih klasifikacija financijskih pokazatelja je: pokazatelj likvidnosti, pokazatelj efikasnosti, pokazatelj zaduženosti, pokazatelj profitabilnosti, pokazatelj financijskih tržišta.⁷ Profitabilnost banke rezultat je kvalitetnih mjera poslovne politike te dobre bankarske strategije. Na temelju ostvarenih performansi, moguće je predvidjeti poslovne rezultate u budućnosti i u skladu s tim donijeti bitne poslovne odluke, stoga je neizostavna kvalitetna analiza različitih pokazatelja.⁸

Svaka banka treba osigurati likvidnost koja predstavlja poslovnu snagu i temelj poslovanja banke. Likvidnost omogućuje bankama transformaciju novčanih sredstava u kreditne i nekreditne plasmane, te pretvaranje potraživanja u novčana sredstva. U protivnom, banke se suočavaju s rizikom likvidnosti, što može rezultirati stečajem. Politikom upravljanja rizikom likvidnosti, banka treba osigurati izvore sredstava u kratkom roku, kako bi mogla uspješno podmiriti tekuće obveze. Pokazatelj likvidnosti stavlja u omjer odobrene kredite i depozite. Što je omjer manji, banka ima bolju likvidnu poziciju. Nedostatak likvidnosti signalizira da se banka suočava sa financijskim problemima, stoga bi investitori trebali obratiti pažnju na vrijednosti ovog pokazatelja.⁹

⁵ Efikasnost: <http://www.poslovni.hr/leksikon/efikasnost-1211> [2.6.2018.]

⁶ Vidučić, L.J., Pepur, S., Šimić Šarić, M. (2015): Financijski menadžment, IX. Izdanje, RRif plus, str. 424

⁷ Ibidem str.441

⁸ Pavković, A. (2004.): Instrumenti vrednovanja uspješnosti poslovnih banaka, Zbornik Ekonomskog fakulteta u Zagrebu, godina 2, broj 1, str. 180

⁹ Prga, I., Vrdoljak, T., Šverko, I.: Upravljanje rizikom likvidnosti korištenjem valutnih swap ugovora, str. 365-366

S obzirom da su banke glavni izvor financiranja gospodarstva, stabilnost bankarskog sektora ključna je za stabilan i razvijen cjelokupni gospodarski sustav. Sa svrhom postizanja i održavanja optimalnih poslovnih rezultata, banke trebaju donijeti odluku o strategiji poslovanja koju će usmjeriti na efikasno ostvarenje temeljnih bankarskih funkcija. Odluku o strategiji poslovanja i poslovnoj politici donose na temelju osnovnih bankarskih načela poslovanja: načelu likvidnosti, načelu sigurnosti i efikasnosti ulaganja sredstava te načelu rentabilnosti.¹⁰

Društveno odgovornim poslovanjem suvremene banke se ne fokusiraju isključivo na ostvarenje vlastitih ciljeva, već uzimaju u obzir i interese društva. Banke brinu o interesno utjecajnim skupinama i njihovim potrebama. Zbog dinamičnih uvjeta u bankarskom sektoru, trebale bi često vršiti analizu učinkovitosti poslovanja, kako bi održale siguran profit, ali i pružile informacije interesno utjecajnim skupinama te ispunile njihova očekivanja. Procjena efikasnosti poslovanja pruža uvid u način na koji banka vodi poslovnu politiku, te može pomoći u donošenju odluka investitorima, ali i nadzornim i regulatornim tijelima.

¹⁰ Katunarić, A. (1988.): Banka, principi i praksa bankovnog poslovanja, Zagreb, str. 583 i str. 590-591

1.2. Predmet istraživanja

Predmet istraživanja ovog rada je procjena učinkovitosti poslovanja poslovnih banaka na području Republike Hrvatske. Teorijskim dijelom rada obuhvatit će se pojam i osnove poslovanja banaka. Kroz analizu financijskih izvještaja prikazat će se financijski pokazatelji među kojima su izabrani kriteriji pomoću kojih će se vršiti procjena uspješnosti poslovanja i rangiranje banaka. Kroz teoriju će se predstaviti pojam i metode višekriterijalnog odlučivanja. S obzirom da banke posluju u dinamičnom sustavu, analiza učinkovitosti poslovanja ključna je kako bi opstale na tržištu, ne samo za banke nego i njene interesno utjecajne skupine.

U empirijskom dijelu istraživanja primjenom višekriterijalne analize na temelju izabranih kriterija analizirat će se poslovna učinkovitost banaka i izvršiti izbor najbolje alternative pomoću metoda jednostavnog zbrajanja težina, TOPSIS i PROMETHEE metode. Višekriterijalno odlučivanje (*Multiple Criteria Decision Making – MCDM*) odnosi se na donošenje odluka u prisutnosti mnogih, najčešće konfliktnih kriterija.¹¹ Procjena važnosti kriterija dobit će se metodom svojstvenog vektora. Odluka o najboljoj alternativu donosi se između 15 banaka koje su ostvarile dobit tijekom 2017. godine. Procjena se vrši na temelju 6 kriterija odabranih proizvoljno i subjektivno od strane autora.

1.3. Ciljevi i svrha istraživanja

Temeljni cilj istraživanja je prikazati metodologiju izračuna višekriterijalne analize, te na osnovu analize izabrati banku koja najučinkovitije posluje temeljem odabranih kriterija. Sljedeći cilj je definirati pojam bankarstva te teorijski obuhvatiti poslovanje banaka. Nadalje, analizom dostupnih financijskih izvještaja definirati i pojasniti kriterije, odnosno financijske pokazatelje, na temelju kojih će se vršiti rangiranje banaka po efikasnosti. U teorijskom dijelu rada cilj je pojasniti pojam višekriterijalnog odlučivanja kao i metode korištene u radu.

Svrha rada je analizirati efikasnost poslovanja banaka na području Hrvatske. Kroz rad se želi dobiti bolji uvid u učinkovitost poslovanja banaka u Hrvatskoj. Metodama višekriterijalnog odlučivanja izvršit će se rangiranje banaka prema poslovnoj učinkovitosti, te prikazati koja banka vodi najefikasniju poslovnu politiku.

¹¹ Babić, Z. (2017): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str. 27

1.4. Metodologija istraživanja

U znanstvenom istraživanju te prilikom analize podataka koristile su se razne znanstvene metode, kako u teorijskom tako u empirijskom dijelu rada. U radu su korišteni sekundarni izvori podataka uključujući različitu dostupnu literaturu te financijske izvještaje promatranih banaka.

Metode istraživanja koje su se koristile prilikom izrade diplomskog rada su sljedeće:¹²

Induktivna metoda – metoda gdje se na temelju pojedinačnih činjenica dolazi do zaključka o općem sudu. Na temelju provedene analize i prikupljene literature metoda indukcije koristit će se u radu za donošenje zaključaka.

Deduktivna metoda – na temelju općih stavova izvode se posebni, odnosno dolazi se do konkretnih pojedinačnih zaključaka.

Metoda analize i sinteze – analiza podrazumijeva raščlanjivanje složenih pojmova i zaključaka na jednostavnije elemente. Sinteza je postupak povezivanja jednostavnih pojmova ili zaključaka u složenije.

Metoda deskripcije – postupak jednostavnog opisivanja činjenica i procesa bez znanstvenog pristupa i dokazivanja

Komparativna metoda – uspoređivanje istih ili srodnih činjenica i odnosa, utvrđivanje sličnosti i razlika među njima koristit će se za uspoređivanje financijskih pokazatelja

Metoda kompilacije – podrazumijeva postupak preuzimanja tuđih rezultata znanstvenoistraživačkog rada, te tuđih stavova i zaključaka

U radu se koriste metode i modeli višekriterijalnog odlučivanja. Koristit će se metoda jednostavnog zbrajanja težina, TOPSIS i PROMETHEE metode prilikom rangiranja banaka na temelju poslovne učinkovitosti. Za procjenu važnosti kriterija koristit će se metoda svojstvenog vektora.

¹² Zelenika, R. (2000.): Metodologija i tehnologija izrade znanstvenog i stručnog djela, str. 295-312

1.5. Doprinos istraživanja

Doprinos istraživanja usmjeren je na analizu i izračun procjene uspješnosti poslovanja hrvatskih banaka primjenom metoda višekriterijalnog odlučivanja.

Istraživanjem se želi teorijski približiti pojam banaka kao i karakteristike poslovanja i način na koji banke funkcioniraju. Definirat će se osnovni bankovni poslovi, te prikazati rizici s kojima se banke susreću. Kroz analizu financijskih izvještaja prikazat će se pokazatelji efikasnosti poslovanja, te osvrnuti na pokazatelje karakteristične za banke kao što su pokazatelji odnosa u bilanci banke, pokazatelji odnosa u računu dobiti i gubitka, pokazatelji profitabilnosti i investiranja, kako bi se dobio uvid u uspješnost poslovanja banaka. Kroz teoriju će se objasniti pojam višekriterijalnog odlučivanja, te opisati metode korištene pri rangiranju banaka prema poslovnoj učinkovitosti. Rezultati proučavanja dostupne literature poslužit će boljem razumijevanju poslovanja banaka.

Metoda višekriterijalne analize pomaže u donošenju kvalitetnih strateških odluka. U radu će se prikazati izračun metoda višekriterijalnog odlučivanja, korak po korak, počevši od odabira kriterija i procjene njihove važnosti metodom svojstvenog vektora, te konačno primjene metoda višestrukog rangiranja i izbora najbolje alternative. Poslovanje banaka odražava se na stabilnost financijskog sustava, stoga svaka poteškoća u poslovanju može poremetiti funkcioniranje financijskog sustava. U skladu s navedenim, nameće se potreba procjene poslovne učinkovitosti kako bi se, sukladno rezultatima analize, donosile kvalitetnije odluke. Metodologija izračuna primjenom višekriterijalne analize prikazana u radu, može poslužiti interesnim skupinama u procjeni učinkovitosti poslovanja banaka, te da na temelju analize i dobivenih informacija donesu odluku o daljnjoj suradnji. Višekriterijalna analiza može poslužiti kao izvrstan alat nadzornim i regulatornim tijelima u procjeni i definiranju efikasnosti banaka te analizi stanja.

1.6. Struktura rada

Diplomski rad bit će podijeljen na šest poglavlja uključujući uvod i zaključak.

U prvom, uvodnom dijelu, opisan je problem i predmet istraživanja, kao i svrha i ciljevi istraživanja. Prikazan je pregled znanstveno istraživačkih metoda koje će biti korištene u radu, te je naveden doprinos istraživanja diplomskog rada.

U drugom dijelu rada teorijski je definiran pojam banaka te osnovne karakteristike poslovanja. Definirani su osnovni poslovi koje vodi banka. Prikazani su rizici s kojima se banke susreću, te pojašnjeni kreditni rizik, rizik likvidnosti i rizik kamatne stope kao najznačajniji rizici u bankarskom poslovanju.

Treći dio odnosi se na analizu pokazatelja uspješnosti poslovanja. Ovdje su teorijski obrađeni pokazatelji odnosa u bilanci banke, pokazatelji odnosa u računu dobiti i gubitka, pokazatelji profitabilnosti i pokazatelji investiranja među kojima će biti odabrano šest pokazatelja temeljem kojih će se vršiti procjena poslovne učinkovitosti u empirijskom dijelu rada.

U četvrtom dijelu objasniti će se pojam i karakteristike višekriterijalnog odlučivanja. Opisat će se metoda svojstvenog vektora koja će biti korištena u radu za procjenu važnosti kriterija. Teorijski će se osvrnuti na tri metode korištene pri rangiranju alternativa, i to metodu jednostavnog zbrajanja težina, TOPSIS i PROMETHEE metode.

U petom empirijskom dijelu vrši se odabir alternativa i kriterija na temelju kojih će se procijeniti efikasnost banaka. U narednom koraku formira se tablica odluke, te procjena važnosti odabranih kriterija metodom svojstvenog vektora. Na kraju se vrši izbor najbolje alternative, odnosno rangiranje banaka po efikasnosti i komparacija rezultata dobivenih metodom jednostavnog zbrajanja težina, TOPSIS i PROMETHEE metodama. Konačno, vrši se interpretacija dobivenih rezultata i donose zaključci.

U šestom, zadnjem dijelu rada iznijet će se zaključak u kojem su prezentirane činjenice i spoznaje do kojih se došlo na temelju provedene analize. Na samom kraju rada navodi se literatura, popis tablica i slika koji su korišteni u radu.

2. OPĆENITO O BANKAMA

2.1. Pojam i uloga banke

Banka je financijska institucija čija je osnovna djelatnost uzimanje i davanje kredita te posredovanje u platnom prometu.¹³ Glavni zadatak banke kao financijskog posrednik je koncentracija novčanih sredstava i odobravanje kredita uz posredovanje u novčanim plaćanjima, čime direktno utječe na razvoj proizvodnje i prometa.¹⁴

Iz definicije se može uočiti kako su tri značajne djelatnosti banke uzimanje kredita, davanje kredita i posredovanje u platnom prometu. Banke uzimanjem kredita od građana u obliku depozita dolaze do potrebnih financijskih sredstava. Kako bi ostvarile zaradu, temeljem prikupljenih financijskih sredstava, banke odobravaju kredite ekonomskim subjektima koji imaju manjak sredstava. Konačno, banke obavljaju poslove platnog prometa za svoje komitente.¹⁵

Kao dvije temeljne funkcije banke izdvajaju se depozitna i kreditna funkcija. Osim te dvije temeljne uloge koje su banke obavljale u gospodarstvu, primanje depozita i plasiranje kredita, s razvojem poslovanja u suvremenom, dinamičnom okruženju razvile su brojne druge uloge kako bi osigurale opstanak na tržištu i udovoljile svojim klijentima:¹⁶

- posrednička uloga – pretvaranje primljenih depozita od domaćinstava u kredite poslovnim tvrtkama
- uloga plaćanja – plaćanje robe i usluga u korist svojih klijenata
- uloga jamca – jamči za svoje komitente pri otplaćivanju kredita kada oni nisu sposobni
- uloga agencije – upravlja i štiti imovinu svojih komitenata te izdaje i otkupljuje njihove vrijednosne papire
- politička uloga – djeluje kao kreditor vladine politike u pokušaju regulacije ekonomije i praćenja socijalnih ciljeva

¹³ Nikolić, N., Pečarić, M. (2012.): Uvod u financije, Ekonomski fakultet Split, str. 137

¹⁴ Katunarić, A. (1988.): Banka, principi i praksa bankovnog poslovanja, Zagreb, str. 27

¹⁵ Nikolić, N., Pečarić, M. (2012.): Uvod u financije, Ekonomski fakultet Split, str. 137, 138

¹⁶ Rose, P. S. (2003.): Menadžment komercijalnih banaka, MATE, Zagreb, str. 8

2.2. BANKOVNI POSLOVI

Temeljna podjela bankovnih poslova je na:¹⁷

- aktivne ili kreditne poslove
- pasivne ili mobilizacijske poslove
- neutralne ili komisijske poslove
- vlastite bankarske poslove

2.2.1. Aktivni ili kreditni poslovi

Aktivni bankovni poslovi vežu se uz odobravanje kredita. Za banku akumulirana novčana sredstva predstavljaju određeni trošak. Stoga ih ona nastoji usmjeriti ekonomskim subjektima kojima su potrebni, kako bi na taj način banka ostvarila prihod od plasmana koji je veći od troška prikupljenih sredstava. Cijena koju klijent plaća za primljeni kredit je kamatna stopa. Kredite koje banka može nuditi klijentima su: lombardni, eskontni, kontokorektni, hipotekarni, dugoročni, kratkoročni krediti i drugi.¹⁸

Banke prikupljena sredstva od štediša plasiraju klijentima za potrebe proizvodnje ili krajnje potrošnje. Odobreni krediti prema ročnosti mogu se podijeliti na kratkoročne i dugoročne kredite. Za razliku od dugoročnog kredita kod kojeg samo dolazi do prenamjene sredstava iz akumulirane novčane mase deponenata u kredite, kratkoročni krediti imaju značajan utjecaj na povećanje novčane mase u opticaju. Plasiranjem kratkoročnog kredita banka stvara novac i povećava novčanu masu koja ima direktan utjecaj na robno-novčane odnose na tržištu. Dugoročni kredit nosi sa sobom veći rizik, jer postoji mogućnost da klijent u određenom trenutku neće biti kreditno sposoban, odnosno neće moći podmiriti preuzete obveze u roku.¹⁹

¹⁷ Gregurek, M., Vidaković, N. (2013.): Bankarsko poslovanje, Visoko učilište EFFECTUS, Zagreb, str. 19

¹⁸ Gregurek, M., Vidaković, N. (2013.): Bankarsko poslovanje, Visoko učilište EFFECTUS, Zagreb, str. 161, 162

¹⁹ Katunarić, A. (1988.): Banka, principi i praksa bankovnog poslovanja, Zagreb, str. 254, 255

2.2.2. Pasivni ili mobilizacijski poslovi

Pasivni poslovi u vidu prikupljanja depozita su osnova svakog bankovnog poslovanja. Koncentracija prikupljenog novca u banci pruža joj veliku financijsku aktivnost koja se razvija s rastom proizvodnje i prometa. Akumulacija novčanih sredstava klijenata pruža banci mogućnost ostvarivanja profita, plasiranjem slobodnih sredstava u obliku kredita. Funkcija pasivnih poslova pruža banci ogroman financijski potencijal, te joj omogućuje širi opseg poslovanja.²⁰

Obavljajući jednu od svoje dvije temeljne funkcije banke prikupljaju sredstva od klijenata. Tu dolazi do prikupljanja novčanih sredstava na razne račune koje klijenti imaju otvorene u banci. Prema namjeni korištenja računi se dijele na:²¹

- tekući račun – putem kojeg građani obavljaju osnovne transakcije
- žiro račun – račun putem kojeg poduzeća ostvaruju svoje poslovanje. Građani preko ovog računa mogu primiti dodatne prihode koji ne dolaze direktno od plaće.
- štedni račun – klijenti na ovom računu dugotrajno drže višak sredstava. Građani obično ugovaraju štedne račune, a poduzeća depozite.

Akumulirana novčana sredstva na računima banaka predstavljaju primarni izvor sredstava za banku. Međutim, kad se banka suoči s nedostatkom sredstava, mora posegnuti za sekundarnim izvorima sredstava. Banka aktivno prikuplja sredstva iz sekundarnih izvora da zadovolji kratkoročne potrebe za likvidnošću, te da bi došla do dugoročnih sredstava koje će namijeniti u dugoročne plasmane.²²

²⁰ Katunarić, A. (1988.): Banka, principi i praksa bankovnog poslovanja, Zagreb, str. 234, 235

²¹ Gregurek, M., Vidaković, N. (2013.): Bankarsko poslovanje, Visoko učilište EFFECTUS, Zagreb, str. 132

²² Gregurek, M., Vidaković, N. (2013.): Bankarsko poslovanje, Visoko učilište EFFECTUS, Zagreb, str. 138, 139

2.2.3. Neutralni poslovi

Najstariji bankovni poslovi koji se javljaju u poslovanju banke su neutralni poslovi. Pritom se ona ne javlja ni kao dužnik ni vjerovnik, već kao posrednik ili jamac. Banka obavlja određene posredničke poslove za svog komitenta i ostvaruje zaradu u obliku provizije. Posrednički poslovi se dijele na:²³

- Posredovanje u platnom prometu – temeljna funkcija platnog prometa je sigurna i učinkovita upotreba novca kao sredstva plaćanja te bezgotovinsko plaćanje odnosno prijenos sredstava od platitelja ka primatelju. Platne usluge koje banke obavljaju su podizanje i polaganje gotovog novca, izvršavanje platnih transakcija kreditnih transfera, trajnih naloga, izdavanje platnih instrumenata i drugo. Platni promet reguliran je Zakonom o platnom prometu i Zakonom o električnom novcu.²⁴
- Depo poslovi (čuvanje i upravljanje vrijednostima) – uslužni bankovni poslovi čuvanja i upravljanja nenovčanih depozita i ostalih vrijednosti. Banka se obvezuje na čuvanje vrijednosnih papira, predmeta od dragocjenih kovina, umjetničkih predmeta, osobnih predmeta i drugih vrijednih stvari, a za uzvrat naplaćuje proviziju.²⁵
- Kupovanje i prodaja vrijednosnih papira – banka se javlja kao posrednik na burzi te kupuje i prodaje vrijednosne papire za svog komitenta²⁶
- Jamstva i garancije – garancija je instrument kojim se banka obvezuje da će korisniku garancije ispuniti obvezu u visini svote istaknute u garanciji ukoliko dužnik nije sposoban ispuniti istu. Porast korištenje garancija posljedica je povećanih rizika u poslovanju.²⁷
- Otvaranje akreditiva – akreditiv je jedan od najsigurnijih instrumenata plaćanja međunarodnog platnog prometa. Podjednako štiti kupca i prodavatelja. Isplata ugovorene svote izvršit će se tek kada prodavatelj priloži dokumentaciju da je usluga izvršena sukladno uvjetima navedenim u akreditivu.²⁸

²³ Katunarić, A. (1988.): Banka, principi i praksa bankovnog poslovanja, Zagreb, str. 265, 266

²⁴ O platnom prometu, <https://www.hnb.hr/temeljne-funkcije/platni-promet/o-platnom-prometu> [21.06.2018.]

²⁵ Poslovni.hr: Depo posao, <http://www.poslovni.hr/leksikon/depo-posao-173> [21.06.2018.]

²⁶ Katunarić, A. (1988.): Banka, principi i praksa bankovnog poslovanja, Zagreb, str. 270

²⁷ Gregurek, M., Vidaković, N. (2013.): Bankarsko poslovanje, Visoko učilište EFFECTUS, Zagreb, str. 91

²⁸ Kreditna banka Zagreb, Akreditivi, <http://www.kbz.hr/poslovno-bankarstvo/akreditivi> [21.06.2018.]

2.2.4. Vlastiti bankovni poslovi

To su poslovi koje banka obavlja u svoje ime i za svoj račun kako bi ostvarila određeni profit. Tu spadaju: *arbitražni poslovi, burzovne špekulacije i osnivanje industrijskih poduzeća sudjelovanjem u dioničarskim društvima*. U *arbitražnim poslovima* banka ostvaruje zaradu na razlici tečajeva vrijednosnih papira na dvije burze. Trgovanjem financijskim instrumentima i stranim valutama banka može ostvariti značajan prihod. Ona kupuje vrijednosne papire na jednoj burzi po nižoj cijeni, da bi ih mogla prodati na drugoj burzi po višoj cijeni i na taj način ostvariti zaradu. *Burzovnim špekulacijama* banka kupuje vrijednosne papire na burzi kako bi stekla zaradu, stoga ih prodaje u trenutku većeg notiranja vrijednosnog papira. S ciljem ostvarivanja profita, banka može *sudjelovati u dioničarskim društvima novoosnovanih poduzeća*. Ulaganjem vlastitog kapitala, banka može ostvariti dobit na račun dobrog poslovanja i pozitivnog financijskog rezultata poduzeća.²⁹

²⁹ Katunarić, A. (1988.): Banka, principi i praksa bankovnog poslovanja, Zagreb, str. 271

2.3. BANKOVNI RIZICI

Banka se u svom poslovanju svakodnevno susreće sa različitim rizicima. Najčešći i najvažniji za banke su upravo kreditni rizik, rizik likvidnosti te rizik promjene kamatne stope, koji će biti opisani u nastavku rada.

2.3.1. Rizik likvidnosti

Rizik s kojim se banka svakodnevno susreće u poslovanju, je upravo rizik likvidnosti. Ukoliko banka ima poteškoće s likvidnošću, tj. nema dovoljno sredstava da podmiri svoje obveze po dospeljeću, ugrožen je njen opstanak, što može voditi stečaju.

Pojedini autori različito tumače pojam rizika likvidnosti. Leko razlikuje širi i uži obuhvat definicije likvidnosti. U užem smislu, rizik likvidnosti ukazuje na opasnost da se vrijednosni papiri neće moći pretvoriti u novčani oblik po željenoj cijeni i u željeno vrijeme. U širem smislu, rizik likvidnosti predstavlja opasnost da se imovina neće moći, bez gubitaka pretvoriti u novac u željeno vrijeme. Dok Prohaska definira rizik likvidnosti kao rizik nemogućnosti naplate potraživanja na dan dospeljeća, te nemogućnost ispunjena obveza za dani kredit.³⁰

Potreba za likvidnošću banke može se promatrati kroz ponudu i potražnju za sredstvima. Potražnja utrživih sredstava kod većine banaka javlja se povlačenjem depozita od strane komitenata te zahtjevima za kreditima od strane komitenata. Kako bi zadovoljila potražnju, banka može buduće likvidne potrebe pokriti iz nekoliko izvora ponude. Privlačenjem novih depozita komitenata ostvaruje priljev svježih sredstava, što je najviše vidljivo početkom mjeseca kada se dijele plaće. Ponudu likvidnih sredstava može ostvariti od komitenata koji otplaćuju kredite. Prodajom aktive, posebno vrijednosnih papira, banka ostvaruje priljev sredstava potrebnih za pokrivanje postojećih manjkova.³¹

Kad potražnja za sredstvima banke premaši ponudu, banka se suočava sa deficitom sredstava, stoga treba brzo djelovati te odlučiti na koji način pribaviti potrebna sredstva. Ukoliko ponuda u banci premaši potražnju, banka će imati suficit sredstava koja će moći dalje plasirati kako bi

³⁰ Prga, I., Vrdoljak, T., Šverko, I. (2009.): Upravljanje rizikom likvidnosti korištenjem valutnih swap ugovora, str. 365

³¹ Rose, P. S. (2003.): Menadžment komercijalnih banaka, MATE, Zagreb, str. 348

ostvarila profit. Gotovo ne postoje situacije u kojima je potražnja za sredstvima jednaka njihovoj ponudi, stoga se menadžment banke uvijek susreće s manjkom ili viškom sredstava, te mora donositi promptne poslovne odluke kako bi osigurao odgovarajuću likvidnost.³²

Ročna neujednačenost aktive i pasive javlja se kada banke privlače sredstva od komitenata na jedan rok, a plasiraju ih onima kojima je potrebno na drugi rok. Klijenti deponiraju sredstva u banci na što kraći rok, dok žele posuditi sredstva na što duži rok. U većini slučajeva priljevi nisu jednaki odljevima, stoga se banka suočava sa neusklađenom ročnom strukturom, pa nastaje problem likvidnosti.³³

Banke u svakom trenutku moraju odgovoriti zahtjevu za likvidnost. Ukoliko komitenti izgube povjerenje u instituciju, može doći do povlačenja sredstava iz banka, čime bi banke ostale bez gotovine, što bi narušilo njihovu funkciju i poslovanje.³⁴

Likvidnost je obrnuto proporcionalna profitabilnosti. Što je banka likvidnija ostvaruje nižu stopu prinosa na vlastiti kapital i imovinu. Zbog toga je strategija upravljanja rizikom likvidnosti prioritet i preduvjet opstanka banaka na tržištu. Upravljanje pasivom podrazumijeva pronalaženje sekundarnih izvora sredstava kad postoji povećana potreba za istima. Danas se banke često okreću prodaji aktive kao i na stvaranje novih zaduženja, stoga je upravljanje aktivom i pasivom podjednako važno u upravljanju rizikom likvidnosti.³⁵

Tehnike upravljanja likvidnošću dijele se na:³⁶

- *Politiku likvidnosti*
- *Zalihe likvidnosti u aktivu*
- *Kratkoročne izvore likvidnosti putem tržišta novca i derivatske poslove*

Banka treba imati jasno definiranu *politiku likvidnosti*. Treba kontrolirati ročnost kredita u aktivu kao i deponiranih sredstava. Banka mora znati koliko sredstava je prikupila, te koliko može prikupiti u budućnosti. Menadžeri trebaju pratiti ponašanje klijenata te predvidjeti kada će deponenti podići svoja sredstva.

³² Rose, P. S. (2003.): Menadžment komercijalnih banaka, MATE, Zagreb, str. 349, 350

³³ Gregurek, M., Vidaković, N. (2013.): Bankarsko poslovanje, Visoko učilište EFFECTUS, Zagreb, str. 358, 359

³⁴ Ercegovac, R. (2016.): Teorija i praksa bankovnog menadžmenta, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 61

³⁵ Jakovčević, D. (2000.): Upravljanje kreditnim rizikom u suvremenom bankarstvu, TEB poslovno savjetovanje, Zagreb, str. 24

³⁶ Gregurek, M., Vidaković, N. (2013.): Bankarsko poslovanje, Visoko učilište EFFECTUS, Zagreb, str. 362, 363

Kada banka prikupi sredstva deponirana na ugovoreni rok, jedan dio tih sredstava treba plasirati u visoko likvidne plasmane, poput depozita kod drugih banaka, kako bi stvorila *zalihe likvidnosti u aktivi* za potrebe buduće potražnje, ukoliko dođe do povlačenja depozita.

Banka može privremeno prikupiti sredstva posuđivanjem od drugih banaka na sekundarnom tržištu, i to kratkoročnim posuđivanjem, REPO poslovima ili SWAP transakcijama. Ovakav način upravljanja likvidnošću ne bi trebalo dugotrajno koristiti i može biti povremeno, jer ukazuje kako je banka primorana posuđivati sredstva od drugih banaka jer nema dovoljno vlastitih sredstava.³⁷

2.3.2. Kreditni rizik

„Kreditni rizik se može definirati kao rizik neplaćanja ili nemogućnosti dužnika da podmiri svoje obveze banci po osnovi glavnice i kamata, u punoj svoti na dogovoren dan dospijea sukladno odredbama ugovora o kreditu.“³⁸

Pojam kreditnog rizika ukazuje da se plaćanje uopće ne mora dogoditi što negativno utječe na novčane tokove i stvara problem likvidnosti. 80% bilance stanja banaka otpada upravo na ovakav oblik upravljanja rizicima, što kreditni rizik uz likvidni čini najznačajnijim uzrokom stečaja banaka.³⁹

Poslovanje banke temelji se na predviđanju budućnosti i potencijalnih rizika. Kreditni rizik nastaje ulaganjem novčanih sredstava u financijske plasmane, dok postoji mogućnost da se uloženi novac neće u cijelosti vratiti. Kako banke posluju u neizvjesnosti, suočavaju se s problemom asimetričnih informacija, ne mogu predvidjeti koji klijent neće ispuniti ugovornu obvezu, stoga je potrebno procijeniti njegovu kreditnu sposobnost. Kreditna sposobnost zajmotražitelja odnosi se na njegovu mogućnost da vrati kredit, a procjenjuje se vrijednošću njegove imovine te praćenjem boniteta zajmotražitelja. Banke prikupljaju što više informacija o klijentu te tako vrše procjenu njegovog boniteta. Zadatak upravljanja kreditnim rizikom je

³⁷ Gregurek, M., Vidaković, N. (2013.): Bankarsko poslovanje, Visoko učilište EFFECTUS, Zagreb, str. 362, 263

³⁸ Kandžija, V., Živko, I. (2014.): Upravljanje bankama, Ekonomski fakultet Sveučilišta, Mostar-Rijeka, str. 237

³⁹ Greuning, H. van, Brajović Bratanović, S. (2006.): Analiza i upravljanje bankovnim rizicima, MATE, Zagreb, str. 135

minimizirati isti, stoga pri utvrđivanju kreditne sposobnosti banke provode analizu sposobnosti klijenta da sukladno ugovoru o kreditu isti vrate u cijelosti banci.⁴⁰

Nadzorni odbor treba osigurati da kreditna uloga banke ostvaruje tri cilja:⁴¹

- Kredite treba odobravati na zdravoj i naplativoj osnovi
- Izvore sredstava treba profitabilno investirati s ciljem ostvarivanja koristi dioničara i zaštite depozitora
- Treba zadovoljiti opravdane kreditne potrebe ekonomskih subjekata

Strategija upravljanja kreditnim rizikom obuhvaća diverzifikaciju kreditnog portfelja. Kreditni portfelj je kombinacija ulagateljskih čestica, kojima menadžment upravlja kako bi ostvario maksimalan prinos na uloženo, uz prihvatljiv stupanj rizika. Upravljanjem kreditnim portfeljom nastoji se minimizirati kreditni rizik. Svaki razuman investitor nastojat će umanjiti rizik diverzifikacijom portfelja, odnosno umjesto ulaganja u jednu ulagateljsku česticu, oblikovat će portfelj sa dvije ulagateljske čestice. Diverzifikacija kreditnog portfelja podrazumijeva širi broj bankovnih produkata, veći broj klijenata i veći broj geografskih lokacija kreditiranja.⁴²

2.3.3. Rizik kamatne stope

Kamatni rizik je vjerojatnost da će vrijednost financijskog instrumenta varirati ovisno o promjeni kamatne stope. Zbog povećanja ili smanjenja kamatne stope, banka može ostvariti dobit ili gubitke po pojedinačnim stavkama ili sveukupno.⁴³

Svako povećanje kamatne stope utječe na ostvarenu zaradu i za banku predstavlja suočavanje s rizikom likvidnosti. Banke će se susresti s prijevremenim povlačenjem depozita, što znači veće troškove, jer banka treba prikupiti dodatna sredstva koja su sada skuplja. U konačnici će

⁴⁰ Kandžija, V., Živko, I. (2014.): Upravljanje bankama, Ekonomski fakultet Sveučilišta, Mostar-Rijeka, str. 299, 300

⁴¹ Greuning, H. van, Brajović Bratanović, S. (2006.): Analiza i upravljanje bankovnim rizicima, MATE, Zagreb, str. 140, 141

⁴² Jakovčević, D. (2000.): Upravljanje kreditnim rizikom u suvremenom bankarstvu, TEB poslovno savjetovanje, Zagreb, str. 165-167

⁴³ Jakovčević, D. (2000.): Upravljanje kreditnim rizikom u suvremenom bankarstvu, TEB poslovno savjetovanje, Zagreb, str. 25

se povećati novčani odljevi i smanjiti dobit banke. Smanjivanje kamatne stope negativno će se odraziti na poslovanje banke, jer novoodobreni krediti u tom slučaju imaju nižu kamatnu stopu.⁴⁴

Profitabilnost poduzeća može biti ugrožena promjenom kamatnih stopa, povećavajući mu troškove, smanjujući povrat od aktive te smanjujući vrijednost vlasničkih uloga u poduzeću.⁴⁵

Cilj upravljanja rizikom kamatnih stopa je umanjiti isti. Podrazumijeva upravljanje strukturom aktive i pasive banke, s ciljem kontroliranja utjecaja promjena kamatnih stopa na financijski rezultat banke.⁴⁶ Strategija upravljanja strukturom aktive podrazumijeva zamjenu nekih stavki aktive s jednim rokom dospeljeća za neke druge stavke aktive s drugim rokom dospeljeća. Zbog procesa ročne transformacije aktive, banke često imaju negativne gapove promjene cijena u kraćim vremenskim razdobljima, a pozitivne u dužim, pa se odlučuju za prodaju dugoročnih stavki aktive za kratkoročnu aktivu, kako bi smanjile izloženost riziku promjene kamatne stope. Strategija upravljanja pasivom uključuje zamjenu stavki pasive s kraćim rokom dospeljeća za stavke pasive s dužim rokovima, kako bi banka izbjegla rizik promjene kamatne stope. Ta strategija još uvijek nije u potpunosti primjenjiva u hrvatskoj bankovnoj praksi, zbog navika građana i problema privlačenja dugoročnih deponenata.⁴⁷

⁴⁴ Kandžija, V., Živko, I. (2014.): Upravljanje bankama, Ekonomski fakultet Sveučilišta, Mostar-Rijeka, str. 259, 260

⁴⁵ Rose, s., Hudgins, S. C. (2015.): Upravljanje bankama i financijske usluge, MATE d.o.o., Zagreb, str. 217

⁴⁶ Kandžija, V., Živko, I. (2014.): Upravljanje bankama, Ekonomski fakultet Sveučilišta, Mostar-Rijeka, str. 240

⁴⁷ Šverko, I. (2007.): Upravljanje nekreditnim rizicima u hrvatskim financijskim institucijama, Hrvatski institut za bankarstvo i osiguranje, str. 103, 104

3. ANALIZA POKAZATELJA USPJEŠNOSTI POSLOVANJA BANKE

Banke posluju u dinamičnom okruženju. Kako bi opstale na tržištu i osigurale vlastiti razvoj, moraju donositi optimalne odluke na temelju prikupljenih informacija. Informacije potrebne za proces planiranja i donošenje kvalitetnih poslovnih odluka sadržane su u financijskim izvještajima. Financijska analiza prikazuje financijski položaj poduzeća, stoga menadžeri analizom financijskih izvještaja mogu izvršiti procjenu uspješnosti poslovanja te ostvariti bolje rezultate u narednom razdoblju.⁴⁸

„Financijska analiza je analitički i prosudbeni proces koji pomaže menadžmentu u ispravnom donošenju odluka.“⁴⁹ Na temelju informacija dobivenih financijskom analizom, procjenom se dolazi do spoznaje o proteklom i budućem poslovanju, što vodi donošenju racionalnih odluka i u konačnici do njihove realizacije. Financijska analiza predstavlja podlogu menadžmentu za donošenje odluka potrebnih za ostvarivanje ciljeva likvidnosti i profitabilnosti poduzeća. Osim menadžmenta, za informacije dobivene financijskom analizom zainteresirani su i drugi korisnici poput: kreditora, investitora, zaposlenih, revizora, države i drugih.⁵⁰

Financijska analiza ili kako se često još naziva analiza financijskih izvještaja prethodi procesu planiranja koji čini sastavni dio upravljanja. Dobar financijski plan treba uzeti u obzir snage i slabosti poduzeća, a zadatak analize financijskih izvještaja je da prepozna snage kako bi se mogle iskoristiti, te otkrije slabosti kako bi se iste određenim akcijama umanjile.⁵¹

Poduzeća sastavljaju godišnje financijske izvještaje kako bi upoznali vanjske i unutarnje korisnike sa financijskim stanjem te poslovanjem poduzeća. To se posebno odnosi na vanjske korisnike koji nemaju direktan pristup računovodstvenim evidencijama. Cilj financijskih izvještaja je pružiti korisnicima realne informacije o financijskom stanju i djelotvornosti poslovanja poduzeća kako bi mogli donositi optimalne poslovne odluke. Te informacije dostupne su u bilanci, računu dobiti i gubitka, izvještaju o novčanim tokovima, izvještaju o promjenama glavnice i bilješkama.⁵²

⁴⁸ Vujević, I. (2005.): Financijska analiza u teoriji i praksi, Ekonomski fakultet, Split, str. 25-27

⁴⁹ Ibidem, str. 34

⁵⁰ Ibidem, str. 32-33

⁵¹ Žager, K., Žager, L. (1999.): Analiza financijskih izvješća, MASMEDIA, Zagreb, str. 157

⁵² Vujević, I. (2005.): Financijska analiza u teoriji i praksi, Ekonomski fakultet, Split, str. 74

3.1. TEMELJNI FINANCIJSKI IZVJEŠTAJI

U Republici Hrvatskoj, Zakonom o računovodstvu reguliran je sadržaj i način sastavljanja godišnjih financijskih izvještaja. Prema Zakonu o računovodstvu godišnji financijski izvještaji su:⁵³

- Bilanca
- Račun dobiti i gubitka
- Izvještaj o novčanim tokovima
- Izvještaj o promjenama kapitala
- Bilješke uz financijske izvještaje

3.1.1. Bilanca

Bilanca je temeljni financijski izvještaj koji prikazuje imovinu, kapital i obveze banke na određeni datum, najčešće zadnji dan poslovne godine. Ona je slika financijskog položaja poduzeća. Prikazuje kako se imovina poduzeća osigurava kapitalom kreditora i vlasnika. Bilanca se sastoji od aktive i pasive. Aktiva, odnosno imovina poduzeća prikazuje se na lijevoj strani, a pasiva, odnosno obveze i glavnica na desnoj strani. Ravnoteža u bilanci postiže se tako da je aktiva uvijek jednaka pasivi. Drugim riječima, vrijednost imovine poduzeća treba uvijek biti jednaka njenim izvorima, odnosno vrijednosti obveza i kapitala.⁵⁴

Aktivu bilance čine potraživanja za upisani a neuplaćeni kapital, dugotrajna imovinu, kratkotrajna imovina, plaćeni troškovi budućeg razdoblja i nedospjela naplata prihoda te eventualno gubitak iznad visine kapitala.⁵⁵ Imovina u aktivi bilance dijeli se na kratkotrajnu i dugotrajnu. *Kratkotrajna imovina* pretvara se u novčani oblik u vremenu kraćem od jedne godine. Osnovni oblici kratkotrajne imovine su novac, kratkotrajna potraživanja (od kupaca, zaposlenih, države), financijska imovina, odnosno plasmani novca na rok kraći od jedne godine, te zalihe (sirovine i materijala, proizvodnje). *Dugotrajna imovina* ostaje duže vezana u poduzeću te se pretvara u novčani oblik u razdoblju dužem od jedne godine. To su

⁵³ Zakon o računovodstvu, NN (120/16): <https://www.zakon.hr/z/118/Zakon-o-ra%C4%8Dunovodstvu> [02.07.2018.]

⁵⁴ Vujević, I. (2005.): Financijska analiza u teoriji i praksi, Ekonomski fakultet, Split, str. 79, 80

⁵⁵ Ibidem, str. 80

materijalna imovina koja ima fizički oblik (zgrade, oprema, prirodna bogatstva), nematerijalna imovina (patenti, koncesije, licence), financijska imovina nastala ulaganjem novčanih sredstava na rok duži od jedne godine (vrijednosni papiri, dani krediti) i dugotrajna potraživanja (za prodanu robu na kredit duži od jedne godine).⁵⁶

Pasiva bilance, odnosno izvori imovine dijele se na vlastite i tuđe, tj. kapital i obveze. Prema ročnosti, obveze se dijele na kratkoročne i dugoročne. Kratkoročne obveze treba podmiriti u roku kraćem od jedne godine, i obuhvaćaju obveze prema dobavljačima za materijal i slično. Dugoročne obveze su sve one koje imaju rok dospeljeća duži od jedne godine, i to mogu biti obveze za primljene dugoročne kredite od banke i slično. Kapital poduzeća čini razlika između ukupne imovine i ukupnih obveza. Uvećava se dodatnim ulaganjem vlasnika i u slučaju uspješnog poslovanja, tj. zadržavanjem dobiti, a umanjuje se raspodjelom vlasnicima te gubicima u poslovanju.⁵⁷

3.1.2. Račun dobiti i gubitka

Račun dobiti i gubitka prikazuje aktivnosti banke u određenom vremenskom razdoblju, tj. prihode i rashode te financijski rezultat, za razliku od bilance koja prikazuje financijski položaj u određenom vremenskom trenutku. Odvijanjem poslovnih procesa nastaju promjene na imovini poduzeća. Pritom se imovina transformira iz jednog oblika u drugi. Dolazi do transformacije novca u materijalni oblik i obratno. U vezi s promjenama na imovini i izvorima imovine nastaju prihodi i rashodi.⁵⁸

Prihodi nastaju povećanjem imovine ili smanjenjem obveza, što ima za posljedicu povećanje kapitala. Javljaju se kao redovni i izvanredni prihodi. U redovne spadaju poslovni i financijski prihodi. Najčešći i najznačajniji su poslovni prihodi koji nastaju prodajom proizvoda i usluga. Financijski prihodi nastaju ulaganjem viška novčanih sredstava u dionice, obveznice, posuđujući novac ili pak od pozitivnih tečajnih razlika. Na taj način ostvaruje se zarada od

⁵⁶ Žager, K., Žager, L. (1999.): Analiza financijskih izvješća, Masmedia, Zagreb, str. 35-38

⁵⁷ Ibidem, str. 38, 39

⁵⁸ Ibidem, str. 44

dividendi ili kamata. Izvanredni prihodi su nepredvidivi, jer se ne pojavljuju često u poslovanju, a nastaju prodajom dugotrajne imovine i sirovina ili otpisom obveza.⁵⁹

Rashodi nastaju trošenjem ili smanjivanjem imovine ili povećanjem obveza, kao takvi uzrokuju smanjenje kapitala. Kao i kod prihoda dijele se na redovne i izvanredne, gdje u redovne spadaju poslovni i financijski rashodi. Poslovni rashodi vezani su uz troškove razdoblja ili troškove od prodanih proizvoda. Financijski rashodi posljedica su korištenja tuđih novčanih sredstava. Izvanredni rashodi ne nastaju često, a javljaju se kao otuđenje imovine ili u obliku kazne i štete.⁶⁰

Ukoliko su prihodi veći od rashoda poduzeće ostvaruje pozitivan financijski rezultat, te na taj način utječe na povećanje kapitala. Kad su prihodi manji od rashoda, poduzeće posluje s gubitkom, te mu se smanjuje kapital.⁶¹

$$\text{FINANCIJSKI REZULTAT} = \text{PRIHODI} - \text{RASHODI}$$

$$\text{PRIHODI} > \text{RASHODI} = \text{DOBIT}$$

$$\text{RASHODI} > \text{PRIHODI} = \text{GUBITAK}$$

⁵⁹ Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 70, 71

⁶⁰ Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 71, 72

⁶¹ Ibidem, str. 69

3.1.3. Izvještaj o novčanom toku

Izvještaj o novčanom toku pruža informacije o izvorima i upotrebi gotovine, te predstavlja temelj za planiranje budućih gotovinskih tijekova i potreba za financiranjem.⁶² Kako bi se dobio uvid prikuplja li poduzeće dovoljno novca iz redovnih aktivnosti, te je li to dovoljno za podmirivanje svakodnevnih obveza, primici i izdaci novca u izvještaju se prikazuju iz:⁶³

- Poslovne aktivnosti
- Investicijske aktivnosti
- Financijske aktivnosti

3.1.4. Izvještaj o promjeni kapitala

Izvještaj prikazuje promjene vlasničkog kapitala tijekom određenog razdoblja. Jedna od promjena je dobit ili gubitak ostvaren u tom razdoblju. Promjene mogu nastati ukoliko poduzeće isplaćuje dividendu u novcu, čime se smanjuje vrijednost novca i vlasničkog kapitala. Izvještaj pruža informacije o kapitalu i pričuvama, isplaćenim dividendama, te promjenama računovodstvenih politika i ispravke temeljnih pogrešaka. Svrha izvještaja je prikazati promjene bogatstva dioničara.⁶⁴

3.1.5. Bilješke uz financijske izvještaje

Bilješke detaljno opisuju pojedine podatke u ranije spomenutim izvještajima. Prikazuju metode procjene bilančnih pozicija, eventualna odstupanja i razloge tih odstupanja, prosječan broj zaposlenih, vrijednost dionica po vrstama i slično. Od velike su važnosti korisnicima s obzirom da prikazuju dodatne informacije koje se ne vide u financijskim izvještajima, te pojašnjavaju određene pozicije u izvještajima koje su iznimno važne za razumijevanje. Bilješke povećavaju kvalitetu i upotrebljivost informacija u financijskim izvještajima.⁶⁵

⁶² Vidučić, L.J., Pepur, S., Šimić Šarić, M. (2015.): Financijski menadžment, IX. izdanje, RRIF plus d.o.o., Zagreb, str. 430

⁶³ Žager, K., Žager, L. (1999.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 58

⁶⁴ Vujević, I. (2005.): Financijska analiza u teoriji i praksi, Ekonomski fakultet, Split, str. 108-109

⁶⁵ Ibidem, str. 110-111

3.2. FINANCIJSKI POKAZATELJI ZA BANKE

Analiza putem financijskih pokazatelja je najčešće korištena analiza. S obzirom da su banke specifične u poslovanju za razliku od ostalih gospodarskih subjekata, tako se i klasifikacija financijskih pokazatelja razlikuje kod banaka:⁶⁶

- Pokazatelji odnosa u bilanci banke
- Pokazatelji odnosa u računu dobiti i gubitka
- Pokazatelji profitabilnosti
- Pokazatelji investiranja

3.2.1. POKAZATELJI ODNOSA U BILANCI BANKE

Navedeni pokazatelji računaju se na temelju podataka iz bilance. Kako bilanca prikazuje financijski položaj banke, formirani su pokazatelji kojima se mjeri stabilnost poslovanja, odnosno financijski položaj. Neki od važnijih pokazatelja koji spadaju u ovu skupinu i koji će biti ukratko opisani u nastavku su: pokazatelji likvidnosti i pokazatelji zaduženosti.⁶⁷

3.2.1.1. POKAZATELJI LIKVIDNOSTI

Pokazatelji likvidnosti prikazuju sposobnost poduzeća da podmiri dospjele kratkoročne obveze. Ukoliko poduzeće nije likvidno, to znači da nema dovoljno sredstava da pokrije svoje obveze. *Odnos danih kredita i primljenih depozita* je bitan pokazatelj likvidnosti banaka. Manji pokazatelj je poželjan jer upućuje na veću likvidnost banke.⁶⁸ Najbolji indikator likvidnosti je *koeficijent tekuće likvidnosti*. Računa se kako je prikazano u tablici 1, kao omjer kratkotrajne imovine i kratkoročnih obveza. Poželjno bi bilo da pokazatelj iznosi 2 ili više. Visoki pokazatelj ukazuje na neadekvatno upravljanje kratkotrajnom imovinom ili slabo korištenje kratkoročnih kredita. Nizak pokazatelj upućuje da se kratkotrajna imovina smanjuje ili da kratkoročne obveze rastu, stoga je potrebno uložiti u neki oblik kratkotrajne imovine ili

⁶⁶ Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 298, 299

⁶⁷ Ibidem, str. 300

⁶⁸ Ibidem, str. 300, 301

smanjiti kratkoročne obveze.⁶⁹ Formule za izračun pokazatelja likvidnosti prikazane su u tablici 1.

Tablica 1. Pokazatelji likvidnosti banke

NAZIV POKAZATELJA	BROJNIK	NAZIVNIK
Odnos danih kredita i primljenih depozita	Dani krediti	Primljeni depoziti
Koeficijent tekuće likvidnosti	Kratkotrajna imovina	Kratkoročne obveze
Odnos kratkotrajne aktive i ukupnih kredita	Kratkotrajna imovina	Ukupni dani krediti

Izvor: Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 300

3.2.1.2. POKAZATELJI ZADUŽENOSTI BANKE

Pokazatelji zaduženosti računaju se podacima iz bilance te mjere koliko se banka financira iz tuđih izvora a koliko iz vlastitih. *Koeficijent vlastitog financiranja* izražava se u postotku, a prikazuje koliki je udio imovine financiran kapitalom. Veći pokazatelj je poželjniji jer upućuje na manju zaduženost banke, što znači da se banka izlaže manjem riziku poslovanja. Nasuprot tome, *koeficijent zaduženosti* prikazuje koliki se udio imovine financira iz obveza. Također se izražava u postotku. Veći pokazatelj upućuje na veću zaduženost banke. Zbroj koeficijenta vlastitog financiranja i koeficijenta zaduženosti iznosi 100%. *Stupanj samofinanciranja klijenata* pokazuje koliko se uspješno sredstva prikupljena od klijenata plasiraju dalje klijentima. Veći pokazatelj ukazuje na manju zaduženost banke.⁷⁰ Način izračunavanja pokazatelja zaduženosti vidljiv je u tablici 2.

⁶⁹ Vidučić, L.J., Pepur, S., Šimić Šarić, M. (2015.): Financijski menadžment, IX. izdanje, RRIF plus d.o.o., Zagreb, str. 442, 443

⁷⁰ Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 301, 302

Tablica 2. Pokazatelji zaduženosti banke

NAZIV POKAZATELJA	BROJNIK	NAZIVNIK
Koeficijent vlastitog financiranja	Kapital	Ukupna imovina
Koeficijent zaduženosti	Ukupne obveze	Ukupna imovina
Stupanj samofinanciranja klijenata	Komercijalna aktiva	Komercijalna pasiva

Izvor: Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 301

3.2.2. POKAZATELJI ODNOSA U RAČUNU DOBITI I GUBITKA

3.2.2.1. POKAZATELJI EKONOMIČNOSTI

Pokazatelj *ekonomičnosti ukupnog poslovanja* računa se kao odnos ukupnih prihoda i ukupnih rashoda. Mjeri koliko se prihoda ostvari po jednoj jedinici rashoda. Za uspješno poslovanje potrebno je ostvariti maksimum prihoda uz minimum rashoda. Parcijalni pokazatelj ekonomičnosti *odnos kamatnih prihoda i rashoda* stavlja u odnos kamatne prihode i kamatne rashode. Kao jednostavna mjera ekonomičnosti banke navodi se *odnos ukupnog prihoda i operativnih troškova*. Operativni troškovi su troškovi plaća, materijala te amortizacija i vrijednosno usklađivanje materijalne i nematerijalne imovine. Poželjno je da pokazatelj bude što veći. Manji pokazatelj ukazuje da se operativni troškovi i vrijednosna usklađenja ne mogu pokriti prihodima. Troškovi zaposlenih predstavljaju značajnu stavku ukupnih troškova, stoga se preko pokazatelja *odnosa ukupnog prihoda i troška zaposlenih* ovi troškovi mjere u svrhu njihove kontrole.⁷¹

⁷¹ Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 303, 304

Tablica 3. Pokazatelji ekonomičnosti

NAZIV POKAZATELJA	BROJNIK	NAZIVNIK
Ekonomičnost ukupnog poslovanja	Ukupni prihodi	Ukupni rashodi
Odnos kamatnih prihoda i rashoda	Kamatni prihod	Kamatni rashod
Odnos ukupnih prihoda i troškova	Ukupan prihod	Operativni troškovi i vrijednosna usklađenja
Odnos ukupnog prihoda i troška zaposlenih	Ukupan prihod	Trošak zaposlenih

Izvor: Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 303

3.2.2.2. POKAZATELJI NEKAMATNIH AKTIVNOSTI BANKE

Moderne banke koje nude diverzificirane i raznovrsne usluge svojim klijentima imaju vrijednost ovog pokazatelja iznad prosjeka bankovnog sustava. S obzirom na sve veću konkurenciju i razvijenost financijskih tržišta, banke se više ne razlikuju po kamatnim stopama, već trebaju nuditi raznovrsne usluge kako bi se diferencirale od konkurenata.⁷² Formule za izračun pokazatelja nekamatnih aktivnosti banke prikazane su u tablici 4.

Tablica 4. Pokazatelji nekamatnih aktivnosti banke

POKAZATELJ	BROJNIK	NAZIVNIK
Udio neto prihoda od naknada u ukupnom prihodu	Neto prihodi od naknade	Ukupan prihod
Udio neto ostalih nekamatnih prihoda u ukupnome prihodu	Ostali neto kamatni prihod	Ukupni prihod

Izvor: Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 304

⁷² Ibidem, str. 304

3.2.3. POKAZATELJI PROFITABILNOSTI

Pokazatelji profitabilnosti banke temeljna su mjera uspješnosti poslovanja banke u prethodnom razdoblju. Profitabilnost poslovanja ukazuje na stabilnost i financijsku uspješnost poslovanja banke, te odražava potencijalni budući rast i razvoj banke. Banke koje ostvaruju profit osnažuju vlastiti kapital kroz samofinanciranje. Praćenje bankovne profitabilnosti od iznimnog je značaja za donošenje razboritih i optimalnih poslovnih odluka.⁷³ Smanjena profitabilnost ukazuje na neefikasno upravljanje bankom.

3.2.3.1. POKAZATELJI RENTABILNOSTI

Rentabilnost imovine (ROA) mjeri sposobnost ostvarivanja zarade angažiranjem prosječne imovine banke kroz određeno razdoblje. Prikazuje koliko se dobiti ostvari po svakoj jedinici imovine. Ukoliko je vrijednost pokazatelja veća od 1, smatra se kako je ulaganje u dionice te banke profitabilno. Računa se kao omjer neto dobiti i ukupne imovine. *Rentabilnost kapitala (ROE)* prikazuje povrat na dionički kapital. Stavlja u odnos neto dobit i vlastiti kapital. Ovaj pokazatelj pokazuje vlasnicima banke koliko je dobit menadžment banke ostvario po svakoj jedinici njihova udjela u kapitalu banke. U uvjetima inflacije ovaj pokazatelj trebao bi biti jednak najmanje stopi inflacije kako bi vrijednost kapitala bila očuvana.⁷⁴ Tablica 5. prikazuje izračun spomenutih pokazatelja.

Tablica 5. Pokazatelji rentabilnosti

POKAZATELJ	BROJNIK	NAZIVNIK
Rentabilnost kapitala (ROE)	Neto dobit	Vlastiti kapital
Rentabilnost imovine (ROA)	Neto dobit (Dobit prije poreza)	Ukupna aktiva

Izvor: Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 305

⁷³ Kundid, A. (2010.): Indikatori profitabilnosti bankovnog poslovanja, Računovodstveno – financijske informacije, Broj 12/2010., str.17

⁷⁴ Pavković A. (2004.): Instrumenti vrednovanja uspješnosti poslovnih banaka, Zbornik Ekonomskog fakulteta u Zagrebu, godina 2, broj 1, str.180, 181

3.2.3.2. POKAZATELJI MARŽE I PROSJEČNIH KAMATNIH STOPA

Neto kamatna marža ili marža kamata prikazuje omjer razlike kamatnih prihoda i rashoda te ukupne aktive. Ovisi o veličini banke, njenom položaju u odnosu na konkurenciju, veličini aktive i slično. Banka bolje posluje ukoliko su marža kamata i *marža naknada* veće, dok se za banke koje imaju manju *maržu operativnih troškova* smatra da su profitabilnije, odnosno uspješnije u poslovanju. Dobro organizirana banka treba maržom kamata pokrivati maržu operativnih troškova.⁷⁵

Tablica 6. Pokazatelji marže i prosječnih kamatnih stopa

POKAZATELJ	BROJNIK	NAZIVNIK
Marža kamata	Neto prihod od kamata	Ukupna aktiva
Marža naknada	Neto prihod od naknada	Ukupna aktiva
Marža operativnih troškova	Operativni troškovi	Ukupna aktiva

Izvor: Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 306

3.2.4. POKAZATELJI INVESTIRANJA

Pokazatelji investiranja mjere efikasnost ulaganja u dionice banke. Pokazatelji investiranja korisni su za investitore koji djeluju na tržištu kapitala. *Dobit po dionici (EPS)* pokazuje profitnu efikasnost običnih dionica banke. Njima se mjeri ostvarena dobit po jednoj dionici. Informacija o dobiti po dionici korisna je kod procjene budućih očekivanih dividendi. *Dividende po dionici (DPS)* pokazuju veličinu tekućeg novčanog toka što ga dioničari ostvaruju godišnje po svakoj dionici. Mjere visinu ostvarene dobiti na temelju koje su isplaćene dividende vlasnicima dionica.⁷⁶

Značajni pokazatelji za dioničare banke su pokazatelji rentabilnosti dionice, odnosno *ukupna i dividendna rentabilnost*. Ukupna rentabilnost je u pravilu veća od dividendne. Dividendna rentabilnost dionice je veća ukoliko se dividende isplaćuju iz kumulirane zadržane dobiti iz

⁷⁵ Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 306

⁷⁶ Pavković A. (2004.): Instrumenti vrednovanja uspješnosti poslovnih banaka, Zbornik Ekonomskog fakulteta u Zagrebu, godina 2, broj 1, str.188, 189

prethodnih razdoblja. Pozitivan trend za investitora je ukoliko se rentabilnost dionice smanji zbog porasta tržišne cijene dionice, međutim negativna situacija za investitora je ukoliko rentabilnost dionice pada kao posljedica smanjenja dobiti po dionici.⁷⁷ *Odnos cijene i dobiti (P/E)* prikazuje koliko su investitori voljni platiti za jednu jedinicu zarade banke. Veći pokazatelj ukazuje na veće bogatstvo dioničara. Poduzeća sa većim pokazateljem su perspektivna, dok su poduzeća s nižim pokazateljem rizičnija.⁷⁸ Izračun pokazatelja prikazan je u tablici 7.

Tablica 7. Pokazatelji investiranja

NAZIV POKAZATELJA	BROJNIK	NAZIVNIK
Dobit po dionici (EPS)	Neto dobit	Broj dionica
Dividenda po dionici (DPS)	Dio neto dobiti za dividende	Broj dionica
Ukupna rentabilnost dionice	Dobit po dionici (EPS)	Tržišna cijena dionice (PPS)
Dividendna rentabilnost dionice	Dividenda po dionici (DPS)	Tržišna cijena dionice (PPS)
Odnos cijene i dobiti (P/E)	Tržišna cijena dionice (PPS)	Dobit po dionici (EPS)

Izvor: Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 307

⁷⁷ Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb, str. 307

⁷⁸ Vidučić, L.J., Pepur, S., Šimić Šarić, M. (2012.): Financijski menadžment, RRIF plus d.o.o., Zagreb, str. 454, 455

4. TEORIJSKE POSTAVKE VIŠEKRITERIJALNOG ODLUČIVANJA⁷⁹

Višekriterijalno odlučivanje podrazumijeva donošenje odluka u prisutnosti mnogih, često konfliktnih kriterija. Problemi koji se rješavaju višekriterijalnim odlučivanjem mogu biti različiti, ali svi imaju zajedničke karakteristike: svi problemi višekriterijalnog odlučivanja imaju nekoliko kriterija koje donositelj odluke mora definirati prije postavljanja problema, kriteriji su većinom u međusobnom konfliktu i svaki kriterij se uglavnom izražava u svojoj jedinici mjere.

Kod višekriterijalnog odlučivanja pretpostavka je da postoji ograničen broj unaprijed određenih alternativa. Optimalna alternativa se odabire na temelju ocjena svih alternativa po nekoliko kriterija. Alternative imaju definiran nivo dostizanja svakog kriterija na temelju čega će se donijeti konačna odluka, odnosno izabrati najbolja alternativa ili rang alternativa, usporedbom alternativa po svakom kriteriju istodobno.

4.1. Procjena važnosti kriterija⁸⁰

Kod višekriterijalnih problema postoji nekoliko, uglavnom konfliktnih kriterija, koji ne moraju biti od jednake važnosti donositelju odluke. Za izračun metoda višekriterijalnog odlučivanja potrebno je odrediti relativnu važnost svakog kriterija.

Postoji nekoliko metoda za procjenu važnosti kriterija ovisno donosi li procjenu pojedinac ili grupa ljudi. Metode za grupno procjenjivanje težina su: rangiranje, ocjenjivanje, usporedba po parovima i Delphi metoda. Najčešće korištene metode procjene važnosti kriterija za jedinstvenog donositelja odluke su: ponderirana metoda najmanjih kvadrata, metoda entropije i metoda svojstvenog vektora koja će se koristiti u radu za određivanje važnosti kriterija te će biti opisana u nastavku.

⁷⁹ Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 27-30

⁸⁰ Ibidem, str. 54-72

4.1.1. Metoda svojstvenog vektora⁸¹

Metodu je razvio Thomas L. Saaty. Donositelj odluke treba usporediti po važnosti sve moguće parove kriterija. Broj procjena donositelja jednak je izrazu $\left(\frac{n}{2}\right) = \frac{n \cdot (n-1)}{2}$, gdje je n broj kriterija.

Kako bi donositelj odluke odredio težine kriterija potrebno je za svaki par kriterija (X_i , X_j) procijeniti njihovu relativnu važnost na način da izabere jednu od tvrdnji:

- a) $a_{ij} = \frac{w_i}{w_j} = 1$, oba kriterija su podjednako važna
- b) $a_{ij} = \frac{w_i}{w_j} \geq 1$, kriterij X_i je važniji od kriterija X_j
- c) $a_{ij} = \frac{w_i}{w_j} \leq 1$, kriterij X_j je važniji od kriterija X_i

Kod tvrdnji b) ili c), intenzitet preferencija, odnosno koliko je jedan kriterij važniji od drugog može se izraziti sa više stupnjeva. Za izražavanje tog intenziteta koristi se Saatyeva skala prikazana u tablici 8, koja ima pet stupnjeva i četiri međustupnja.

Tablica 8. Saatyeva skala važnosti

INTENZITET VAŽNOSTI	DEFINICIJA	OBJAŠNJENJE
1	Jednaka važnost	Dva kriterija pridonose jednako danom cilju
3	Slaba preferencija jednog nad drugim	Iskustvo i prosudbe slabo favoriziraju jedan kriterij nad drugim
5	Bitna ili jaka preferencija	Iskustvo i prosudbe jako favoriziraju jedan kriterij nad drugim
7	Uvjerljiva preferencija	Jedan kriterij je u prednosti nad drugim i njegova dominacija je dokazana u praksi
9	Apsolutna preferencija	Očita prednost najvišeg mogućeg ranga jednog kriterija nad drugim
2, 4, 6, 8	Međuvrijednosti između dviju susjednih procjena	Kada je potreban kompromis

Izvor: Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 74

⁸¹ Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 72-77

Uz pomoć Saatyve skale definiraju se omjeri važnosti za sve parove kriterija na temelju čega se formira matrica međusobnih usporedbi A čiji su elementi a_{ij} .

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix} = \begin{bmatrix} w_1/w_2 & w_1/w_2 & \dots & w_1/w_n \\ w_2/w_1 & w_2/w_2 & \dots & w_2/w_n \\ \dots & \dots & \dots & \dots \\ w_n/w_1 & w_n/w_2 & \dots & w_n/w_n \end{bmatrix} \quad (1)$$

gdje je $a_{ij} = \frac{w_i}{w_j}$. (2)

Matrica A ima sve pozitivne elemente a_{ij} i za nju vrijedi svojstvo reciprociteta,

$$a_{ij} = \frac{1}{a_{ji}} \quad (3)$$

tj. element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale jer vrijedi odnos $\frac{w_i}{w_j} = \frac{1}{w_j/w_i}$.

Matrica A ima rang 1. Ima samo jednu svojstvenu vrijednost i ona je jednaka n.

Pretpostavka je da je procjena omjera važnosti donesena konzistentno, međutim često se u procesu odlučivanja javljaju problemi nekonzistentnosti. Posljedica toga je gubitak onih svojstava omjera važnosti zbog koji je matrica A imala samo jednu svojstvenu vrijednost. U tom slučaju od svih svojstvenih vrijednosti bira se najveća, a razlika između najveće svojstvene vrijednosti matrice A i broja n služi za izračun konzistentnosti procjena u matrici.

Indeks konzistencije računa se kao: $CI = \frac{\lambda_{\max} - n}{n - 1}$, (4)

dok se omjer konzistencije računa kao: $CR = CI / RI$, (5)

gdje je RI slučajni indeks prikazan u tablici 9. s izračunatim vrijednostima.

Tablica 9. Slučajni indeks RI

<i>n</i>	1	2	3	4	5	6	7	8	9	10
<i>RI</i>	0	0	0.52	0.89	1.11	1.25	1.35	1.40	1.45	1.49

Izvor: Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 76

Procjene omjera relativnih važnosti kriterija se smatraju prihvatljivima, ukoliko je omjer konzistencije manji ili jednak 0,10.

Primjena metode svojstvenog vektora osim softverskim paketima može se provesti jednostavnijim aproksimativnim postupkom u dva koraka:

1. Prvo je potrebno transformirati matricu međusobnih usporedbi na način da se svaki element te matrice podijeli sa sumom stupca u kojem se nalazi
2. Težine se računaju kao prosječne vrijednosti elemenata pojedinih redaka matrice A

U tom slučaju težine će biti normalizirane, odnosno suma im je jednaka jedan, te će se dobiti točne vrijednosti težina kod potpuno konzistentne matrice.

4.2. Metoda jednostavnog zbrajanja težina – SAW⁸²

Ovo je jedna od najčešće korištenih metoda višekriterijalnog odlučivanja. Prema ovoj metodi svakom kriteriju se dodjeljuje ponder važnosti dobiven nekom od metoda. Težine kriterija tada postaju koeficijenti varijabli iz matrice odluke i to tako da se ponderirane vrijednosti (konačan skor) za svaku alternativu dobiju množeći podatke iz matrice odluke za svaki kriterij s težinom tog kriterija. Sumirajući umnoške preko svih kriterija dobije se konačna ocjena za svaku alternativu. Kraće rečeno, konačan skor dobije se skalarnim množenjem vrijednosti za svaku alternativu i zadanih težina kriterija. Alternativa koja ima najveći skor se smatra najboljom.

Matematički se metoda može prikazati jednostavno:

$$A^* = \left\{ A_i \mid \max_i \frac{\sum_{j=1}^n w_j x_{ij}}{\sum_{j=1}^n w_j} \right\} \quad (6)$$

x_{ij} – procjena i-te alternative po j-tom kriteriju u numerički usporedivoj skali

⁸² Ibidem, str. 128-132

Često su težine normalizirane pa vrijedi $\sum w_j=1$, to znači da u formuli (6) nema nazivnika. Ukoliko elementi matrice odluke nisu u istim mjernim jedinicama potrebno je provesti njihovu transformaciju. U ovom slučaju koristi se linearna transformacija. Ona se provodi posebno za benefit kriterije „što više to bolje“, a posebno za troškovne kriterije „što manje to bolje“. Kod benefit kriterija procjene po svakom kriteriju je potrebno podijeliti s njihovom maksimalnom vrijednošću. Tada najbolja alternativa za taj kriterij dobiva ocjenu jedan, a ostale su izražene u postotku. Kod troškovnih kriterija minimalna vrijednost po svakom kriteriju dijeli se sa ostalim elementima odgovarajućeg kriterija. Na taj način su svi kriteriji prikazani u benefit obliku, odnosno „što više to bolje“.⁸³

4.3. TOPSIS metoda⁸⁴

Prema TOPSIS metodi najbolja alternativa je ona koja ima najmanju udaljenost od idealne alternative i najveću udaljenost od antiidealne alternative. TOPSIS metoda promatra udaljenost od idealne i antiidealne alternative pomoću tzv. relativne bliskosti i tako određuje konačan rang alternativa.

Postupak primjene TOPSIS metode:

1. *Odrediti idealno i antiidealno rješenje*

Idealna alternativa se može definirati kao ona koja ima najbolje vrijednosti po svakom kriteriju, tj.

$$A^+ = \{ (\max x_{ij} | j \in J), (\min x_{ij} | j \in J'), i = 1, 2, \dots, m \} = \\ = \{ x_1^+, x_2^+, \dots, x_n^+ \} \quad (7)$$

J – skup indeksa benefit

J' – skup indeksa troškovnih kriterija

Antiidealna alternativa je

$$A^- = \{ (\min x_{ij} | j \in J), (\max x_{ij} | j \in J'), i = 1, 2, \dots, m \} =$$

⁸³ Ibidem, str. 39, 40

⁸⁴ Ibidem, str. 132-142

$$= \{ x_1^-, x_2^-, \dots, x_n^- \} \quad (8)$$

2. Transformacija atributa

Kako bi se dobile jednake mjerne jedinice za međusobnu usporedbu kriterija potrebno ih je transformirati. Jedna od načina je vektorska transformacija. Svaki element x_{ij} matrice odluke treba podijeliti s normom j-tog stupca u kojem se taj element nalazi. Norma j-tog stupca se računa po formuli:⁸⁵

$$\|X\| = \sqrt{\sum_{i=1}^m x_{ij}^2} = \sqrt{x_{1j}^2 + x_{2j}^2 + \dots + x_{mj}^2} \quad (9)$$

m – broj alternativa u matrici odluke

na taj način dobije se transformirana matrica odluke $R=[r_{ij}]$, gdje je

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m x_{ij}^2}}, \quad \forall i, j. \quad (10)$$

3. Izračunavanje udaljenosti

Potrebno je pridružiti skup težina kriterija dobiven nekom od metoda:

$$W = w_1, w_2, \dots, w_n$$

Tada se može računati udaljenost bilo koje alternative od A^+ i A^- kao ponderirana Euklidska udaljenost na način:

$$S_{i+} = d(A_i, A^+) = \|W \cdot (\bar{A} - \bar{A}^+)\| = \sqrt{\sum_{j=1}^n [w_j \cdot (t_{ij} - t_j^+)]^2} = \sqrt{\sum_{j=1}^n \left[\frac{w_j (x_{ij} - x_j^+)}{\|X_j\|} \right]^2} \quad (11)$$

Slično je udaljenost od negativnog ideala:

⁸⁵ Ibidem, str. 38

$$S_{i-} = d(A_i, A^-) = \left\| W \cdot (\bar{A} - \bar{A}^-) \right\| = \sqrt{\sum_{j=1}^n [w_j \cdot (t_{ij} - t_j^-)]^2} = \sqrt{\sum_{j=1}^n \left[\frac{w_j (x_{ij} - x_j^-)}{\|X_j\|} \right]^2} \quad (12)$$

4. Izračunavanje relativne bliskosti s idealnim rješenjem

Konačan rang alternativa dobije se računanjem relativne bliskosti. Relativna bliskost RC_i u odnosu na idealno rješenje A^+ se definira kao:

$$RC_i = \frac{S_{i-}}{S_{i+} + S_{i-}} \quad (13)$$

Alternativa je bolja što je RC_i bliže jedinici.⁸⁶

4.4. PROMETHEE metoda⁸⁷

PROMETHEE metoda je jedna od metoda višekriterijalnog odlučivanja, kojom se vrši rangiranje različitih alternativa na temelju nekoliko kriterija istodobno.

Višekriterijalni problem javlja se u obliku:

$$\text{Max} \{f_1(a), f_2(a), \dots, f_n(a) \mid a \in A\} \quad (14)$$

gdje je A konačan skup alternativa, odnosno $A = \{A_1, A_2, \dots, A_m\}$, a f_j su n kriterija koje treba maksimizirati. Za svaku alternativu A_i vrijedi da je $f_j(A_i)$ vrijednost ili procjena vrijednosti j -tog kriterija za i -tu alternativu.

Kod usporedbe dviju alternativa a i b potrebno je te rezultate izraziti u terminima preferencija. Stoga se uvodi funkcija preferencije P :

$$P: A \times A \rightarrow [0, 1] \quad (15)$$

Ta funkcija je intenzitet preferencije alternative a u odnosu na alternativu b i definira se kao:

⁸⁶ Ibidem, str. 132-142

⁸⁷ Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 152-173

$P(a, b) = 0$	predstavlja indiferenciju između a i b
$P(a, b) \approx 0$	predstavlja slabu preferenciju a nad b
$P(a, b) \approx 1$	predstavlja jaču preferenciju a nad b
$P(a, b) = 1$	predstavlja strogu preferenciju a nad b

Funkcija preferencije jednaka je razlici u ocjenama između vrijednosti dvije alternative po nekom kriteriju, stoga je :

$$d = f(a) - f(b) \quad (16)$$

Ukoliko je razlika u ocjenama dviju alternativa veća, to je $P(a, b)$ bliže jedinici. Ako za neku vrijednost d funkcija postane jedan, u tom slučaju postoji stroga preferencija. Kad je vrijednost d manja ili jednaka nuli, tad ne postoji preferencija a nad b pa je i $P(a, b) = 0$.

Za svaki kriterij f_j razmatra se generalizirani kriterij definiran pomoću kriterija f_j i odgovarajuće funkcije preferencije. Autori metode predložili su šest tipova generaliziranog kriterija, od koji donositelj odluke bira jedan za svaki kriterij, na temelju informacija o intenzitetu i smjeru preferencije, unaprijed određujući sljedeće parametre:

q - prag indiferencije, kojim se definira područje unutar kojeg je razlika ocjena dviju alternativa po nekom kriteriju zanemariva za donositelja odluke

p - prag preferencije, kojim se definira područje stroge preferencije


s - parametar čija se vrijednost nalazi između praga indiferencije q i praga preferencije p

Šest tipova generaliziranog kriterija su:

1. Obični kriterij

$$P(d) = \begin{cases} 0, & d \leq 0 \\ 1, & d > 0 \end{cases} \quad (17)$$

U ovom slučaju indiferencija između a i b postoji ako i samo ako je $f(a) = f(b)$, tj. za $d=0$. Ukoliko su ocjene dviju alternativa različite to znači da donositelj odluke preferira alternativu koja ima veću ocjenu, te je vrijednost funkcije preferencije jednaka 1 i prikazana na slici 1.




Slika 1. Obični kriterij

Izvor: Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 155

2. Kvazi kriterij

$$P(d) = \begin{cases} 0, & d \leq q \\ 1, & d > q \end{cases} \quad (18)$$

Kod ovog kriterija postoji prag indiferencije q . Dvije alternative su indiferentne sve dok im razlika ocjena ne premaši prag q , u suprotnom postoji stroga preferencija, odnosno vrijednost funkcije preferencije jednaka je jedan, što se vidi iz slike 2. U ovom slučaju parametar q ima strogo ekonomsko značenje.



Slika 2. Kvazi kriterij


Izvor: Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 155

3. Kriterij s linearnom preferencijom

$$P(d) = \begin{cases} 0, & d \leq 0 \\ \frac{d}{p}, & 0 < d < p \\ 1, & d \geq p \end{cases} \quad (19)$$

Sve dok je vrijednost d manja od praga preferencije p , preferencija donositelja odluke raste linearno s vrijednošću d . Kad razlika d prijeđe vrijednost p postoji stroga preferencija, tj.

vrijednost funkcije preferencije jednaka je 1. Za ovaj kriterij treba odrediti samo parametar p , iznad kojeg se javlja stroga preferencija, kao na slici 3.




Slika 3. Kriterij s linearnom preferencijom

Izvor: Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 156

4. Nivo kriterij

$$P(d) = \begin{cases} 0, & d \leq q \\ \frac{1}{2}, & q < d \leq p \\ 1, & d > p \end{cases} \quad (20)$$

Kod ove funkcije potrebno je definirati oba praga q i p . Kad je razlika u ocjenama d manja od vrijednosti q , nema nikakve preferencije, ako pak razlika d premaši vrijednost p postoji stroga preferencija, odnosno vrijednost funkcije preferencije je 1. Ukoliko se razlika u ocjenama d nalazi između vrijednosti pragova postoji slaba preferencija. Slika 4.




Slika 4. Nivo kriterij

Izvor: Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 156

5. Kriterij s linearnom preferencijom i područjem indiferencije

$$P(d) = \begin{cases} 0, & d \leq p \\ \frac{d-q}{p-q}, & q < d \leq p \\ 1, & d > p \end{cases} \quad (21)$$

Sve dok je razlika d ispod vrijednosti q , nema preferencije između dvije alternative. Preferencija donositelja odluke raste linearno u području indiferencije do područja stroge preferencije, odnosno između pragova q i p . Kad razlika u ocjenama d prijeđe iznad praga p postoji stroga preferencija.




Slika 5. Kriterij s linearnom preferencijom i područjem indiferencije

Izvor: Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 157

6. Gaussov kriterij

$$P(d) = \begin{cases} 0, & d \leq 0 \\ 1 - e^{-d^2/2s^2} & d > 0 \end{cases} \quad (22)$$

Kod ove funkcije potrebno je definirati parametra s koji leži u području slabe preferencije, a predstavlja standardnu devijaciju normalne razdiobe. Ova funkcija je zanimljiva zbog stabilnosti rezultata.



Slika 6. Gaussov kriterij


Izvor: Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 157

Kod ove metode potrebno je osim gore navedenih funkcija za svaki kriterij odrediti i relativne važnosti kriterija, nekom od metoda. U sljedećem koraku potrebno je definirati *indeks preferencije* Π , kao ponderiranu sredinu funkcija preferencije P , odnosno:

$$\Pi(a,b) = \frac{\sum_{j=1}^n w_j P_j(a,b)}{\sum_{j=1}^n w_j} \quad (23)$$

Ovaj indeks izražava kako i s kojim intenzitetom a dominira nad b uzimajući u obzir sve kriterije.

Između dvije alternative postoje dva luka $\Pi(a,b)$ i $\Pi(b,a)$. Slika 7. Za svaku alternativu definiraju se dva toka. $\Phi^+(a)$, pozitivni ili izlazni tok i $\Phi^-(a)$, negativni ili ulazni tok. Izlazni tok predstavlja sumu vrijednosti svih lukova koji izlaze iz alternative a i prikazuje koliko je alternativa a bolja od svih ostalih alternativa po svim kriterijima. S druge strane, ulazni tok je suma vrijednosti svih lukova koji ulaze u alternativu a i pokazuje koliko je alternativa a slabija od svih ostalih alternativa po svim kriterijima.



Slika 7. Lukovi $\Pi(a,b)$ i $\Pi(b,a)$

Izvor: Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 158

Usporedbom ulaznih i izlaznih tokova dobiju se dva potpuna uređaja skupa alternativa, jedan po $\Phi^+(a)$ i drugi po $\Phi^-(a)$:

$$\Phi^+(a) \begin{cases} aS^+b & \text{ako i samo ako je } \Phi^+(a) > \Phi^+(b) \\ aI^+b & \text{ako i samo ako je } \Phi^+(a) = \Phi^+(b) \end{cases} \quad (24)$$

$$\Phi^-(a) \begin{cases} aS^-b & \text{ako i samo ako je } \Phi^-(a) < \Phi^-(b) \\ aI^-b & \text{ako i samo ako je } \Phi^-(a) = \Phi^-(b) \end{cases} \quad (25)$$

Presjek ova dva uređaja rezultira u parcijalnom uređaju što je konačan uređaj dobiven metodom PROMETHEE I i prikazan je u tablici 10.

Tablica 10. PROMETHEE I – parcijalni uređaj

$a P b$ (a dominira nad b)	ako i samo ako $\left\{ \begin{array}{c} aS^+b \quad i \quad aS^-b \\ ili \\ aS^+b \quad i \quad aI^-b \\ ili \\ aI^+b \quad i \quad aS^-b \end{array} \right\}$
$a I b$ (a je indiferentan sa b)	ako i samo ako $a I^+ b \quad i \quad a I b$
$a R b$ (a i b su neusporedivi)	U ostalim slučajevima

Izvor: Babić, Z. (2017.): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split, str. 160

Za potpuni uređaj potrebno je računati neto tok Φ , prikazan relacijom (26), odnosno razliku pozitivnog i negativnog toka svake alternative. Taj uređaj zove se PROMETHEE II. Iako je lakše odlučivati na temelju kompletnog poretka, ipak PROMETHEE I daje realnije informacije koje su relevantne prilikom donošenja konačne odluke.

$$\Phi(a) = \Phi^+(a) - \Phi^-(a) \quad (26)$$

5. PRIMJENA METODA VIŠEKRITERIJALNOG ODLUČIVANJA NA PROBLEM PROCJENE EFIKASNOSTI BANAKA

1.1. Odabir alternativa i kriterija

Na području Republike Hrvatske koncem 2017. godine poslovale su 24 poslovne banke. Istraživanje je provedeno na 15 banaka koje imaju javno dostupne financijske izvještaje te su ostvarile pozitivan financijski rezultat u 2017. godini. Financijski izvještaji preuzeti su sa web stranica banke ili Zagrebačke burze.

Odabir najbolje alternative vrši se između 15 banaka koje djeluju na području Republike Hrvatske krajem 2017. godine. Banke koje su ostvarile gubitak u navedenoj godini izostavljene su iz procjene uspješnosti poslovanja. Analizom alternativa želi se utvrditi koja od banaka najuspješnije posluje na temelju izabranih kriterija u navedenoj godini.

Problem odabira najefikasnije banke može se razmatrati kroz niz različitih kriterija, poput pokazatelja ekonomičnosti, likvidnosti, investiranja, upravljanja rizikom. Izbor kriterija je subjektivan i prepušten u potpunosti donositelju odluke. U ovom radu, na temelju preferencija autorice, odabrano je šest kriterija svrstanih u četiri kategorije pokazatelja i to:

- *pokazatelji profitabilnosti* - rentabilnost imovine, rentabilnost kapitala, neto kamatna marža
- *pokazatelji zaduženosti* - koeficijent vlastitog financiranja
- *pokazatelji ekonomičnosti* - odnos kamatnih prihoda i kamatnih rashoda
- *pokazatelji likvidnosti* - odnosa danih kredita i primljenih depozita

Dominantan i najvažniji pokazatelj u ovom radu je profitabilnost, jer navedeni pokazatelj mjeri financijsku uspješnost banke te koliko su menadžeri efikasni u ostvarivanju bankovnih ciljeva.

Formule za izračun navedenih financijskih pokazatelja opisane su u poglavlju 3.2.

Tablica 11 prikazuje alternative i izračunate pokazatelje na temelju dostupnih financijskih izvještaja koji će se koristiti pri procjeni efikasnosti.

Tablica 11. Banke i financijski pokazatelji

BANKE	PROFITABILNOST			ZADUŽENOST	EKONOMIČNOST	LIKVIDNOST
	C1 (%)	C2 (%)	C3 (%)	C4	C5	C6
1. Addiko Bank d.d.	0,73	8,03	2,27	0,14	2,82	0,65
2. Banka Kovanica d.d.	0,46	4,54	5,15	0,10	4,7	0,85
3. Erste&Steiermärkische Bank d.d.	0,97	5,57	3,14	0,12	4,75	0,88
4. Hrvatska poštanska banka d.d.	0,066	0,41	2,68	0,10	4,85	0,65
5. Istarska kreditna banka Umag d.d.	0,95	8,85	2,21	0,09	3,95	0,53
6. Karlovačka banka d.d.	0,35	5,42	2,37	0,06	3,07	0,58
7. KentBank d.d.	0,25	2,27	2,89	0,11	3,55	0,70
8. Kreditna banka Zagreb d.d.	0,75	6,17	2,36	0,10	2,61	0,77
9. OTP banka Hrvatska d.d.	0,33	1,04	2,68	0,26	5,91	0,79
10. Partner banka d.d.	0,46	3,51	2,43	0,11	2,79	0,67
11. Podravska banka d.d.	0,53	3,22	2,33	0,13	3,21	0,70
12. Privredna banka Zagreb d.d.	1,60	8,11	2,82	0,16	6,53	0,82
13. Raiffeisenbank Austria d.d.	0,85	4,01	2,67	0,14	5,04	0,72
14. Slatinska banka d.d.	0,08	0,39	2,57	0,10	2,82	0,61
15. Zagrebačka banka d.d.	1,01	5,76	2,74	0,14	2,78	0,82

Izvor: Izrada autorice

Rentabilnost imovine (C1) – prikazuje koliko se dobiti ostvari po jednoj jedinici imovine. Pokazatelj je bolji ukoliko mu je vrijednost veća od 1. Iz tablice 11 je vidljivo da je ulaganje u dionice Privredne banke Zagreb i Zagrebačke banke profitabilno s obzirom da imaju pokazatelj rentabilnosti imovine veći od jedan, a slijede ih Erste&Steiermärkische Bank i Istarska kreditna banka Umag sa vrijednosti pokazatelja nešto ispod jedan.

Rentabilnost kapitala (C2) – prikazuje kolika se dobit ostvari po svakoj jedinici udjela u kapitalu banke. Veća vrijednost pokazatelja je ujedno i bolja. Visoku vrijednost pokazatelja rentabilnosti kapitala imaju Addiko Bank, Istarska kreditna banka Umag te Privredna banka Zagreb.

Neto kamatna marža (C3) - prikazuje omjer neto prihoda od kamata i ukupne aktive. Prema navedenom pokazatelju banke koje bolje posluju su Banka Kovanica i Erste&Steiermärkische Bank, s obzirom da imaju veći pokazatelj neto kamatne marže. Ostale banke imaju sličnu vrijednost pokazatelja nešto iznad 2.

Koeficijent vlastitog financiranja (C4) – prikazuje koliki je udio imovine financiran kapitalom. Manje zadužene banke koje imaju veću vrijednost pokazatelja su Addiko Bank (0,14), OTP banka Hrvatska (0,26), Privredna banka Zagreb (0,16), Raiffeisenbank Austria (0,14) te Zagrebačka banka (0,14), što znači da se izlažu manjem riziku poslovanja.

Odnos kamatnih prihoda i rashoda (C5) – prikazuje koliko se kamatnih prihoda ostvari po jedinici kamatnih rashoda. Veću vrijednost pokazatelja imaju OTP banka Hrvatska, Privredna banka Zagreb te Raiffeisenbank Austria.

Odnos danih kredita i primljenih depozita (C6) – ovaj pokazatelj likvidnosti upućuje na sposobnost banke da pokrije dospjele obveze. Veću likvidnost imaju banke sa manjim pokazateljem i to Istarska kreditna banka Umag (0,53), Karlovačka banka (0,58) i Slatinska banka (0,61).

1.2. Određivanje težina kriterija primjenom metode svojstvenog vektora

Nakon što su definirani kriteriji te izračunati financijski pokazatelji pristupa se određivanju težina kriterija. Izračun težina kriterija kao i metode jednostavnog zbrajanja težina i TOPSIS metode vrši se u Microsoft Excelu.

Kod procjene važnosti kriterija u višekriterijalnim problemima koriste se različite metode. Metodom svojstvenog vektora, koja je opisana u poglavlju 4.1.1., vršit će se procjena važnosti kriterija u nastavku rada.

U prvom koraku metode svojstvenog vektora potrebno je rangirati kriterije po važnosti. Kriteriji se uspoređuju pomoću Saatyve skale. Zatim se formira matrica međusobnih usporedbi kojoj je potrebno izračunati sumu svakog stupca što se može vidjeti u tablici 12, te se transformacijom matrice dobivaju težine za svaki kriterij.

Prema preferencijama autorice kriteriji su poredani po važnosti:

C1 – Rentabilnost imovine (ROA)

C2 – Rentabilnost kapitala (ROE)

C6 – Odnos danih kredita i primljenih depozita

C4 – Koeficijent vlastitog financiranja

C5 – Odnos kamatnih prihoda i kamatnih rashoda

C3 – Neto kamatna marža

Tablica 12. Matrica međusobnih usporedbi

<i>Poredak važnosti kriterija prema preferencijama autorice: C1, C2, C6, C4, C5, C3</i>						
	C1	C2	C3	C4	C5	C6
C1	1	2	6	4	5	3
C2	0,5	1	6	3	5	2
C3	0,16667	0,16667	1	0,25	0,33333	0,2
C4	0,25	0,33333	4	1	3	0,5
C5	0,2	0,2	3	0,33333	1	0,33333
C6	0,33333	0,5	5	2	3	1
Σ	2,45	4,2	25	10,58333	17,33333	7,033333

Izvor: Izrada autorice

Dobivanje vrijednosti težina zadanih kriterija vrši se aproksimativnim postupkom metodom svojstvenog vektora. Matrica međusobnih usporedbi transformira se tako da se svaki element matrice podijeli sa sumom stupca. Transformirana matrica prikazan je u tablici 13. Konačno, težine kriterija dobiju se kao prosječna vrijednost pojedinog retka transformirane matrice, te su prikazane u zadnjem stupcu tablice 13.

Tablica 13. Transformirana matrica i težine kriterija

	C1	C2	C3	C4	C5	C6	W_i - Težine
C1 – Rentabilnost imovine (ROA)	0,4082	0,4762	0,2400	0,3780	0,2885	0,4265	0,3696
C2 – Rentabilnost kapitala (ROE)	0,2041	0,2381	0,2400	0,2835	0,2885	0,2844	0,2564
C3 – Neto kamatna marža	0,0680	0,0397	0,0400	0,0236	0,0192	0,0284	0,0365
C4 – Koeficijent vlastitog financiranja	0,1020	0,0794	0,1600	0,0945	0,1731	0,0711	0,1133
C5 – Odnos kamatnih prihoda i rashoda	0,0816	0,0476	0,1200	0,0315	0,0577	0,0474	0,0643
C6 – Odnos danih kredita i primljenih depozita	0,1361	0,1190	0,2000	0,1890	0,1731	0,1422	0,1599

Izvor: Izrada autorice

Iz tablice 13 u zadnjem stupcu težina kriterija može se vidjeti da je najvažniji kriterij rentabilnost imovine (ROA). S obzirom da je ovaj kriterij temeljni pokazatelj profitabilnosti te da pokazuje uspješnost banke u ostvarivanju ekonomske koristi, ne čudi da je upravo taj kriterij najvažniji te njegova važnost iznosi 36,96% u odnosu na ostale kriterije.

Sljedeći bitan kriterij za donositelja odluke pri procjeni učinkovitosti poslovanja banke je rentabilnost imovine (ROE) koji iznosi 25,64%.

Na trećem i četvrtom mjestu po važnosti za donositelja odluke su odnos danih kredita i primljenih depozita, sa 15,99%, te koeficijent vlastitog financiranja čija težina u ovom slučaju iznosi 11,33%. Utjecaj likvidnosti banke manje je bitan od prva dva kriterija, ali svakako važniji od preostalih kriterija u procjeni učinkovitosti poslovanja, s obzirom da ukazuje na sposobnost banke da podmiri svoje dospjele obveze. Važnost pokazatelja zaduženosti leži u

činjenici da korištenjem vlastitih izvora financiranja u većoj mjeri, banka se manje izlaže riziku poslovanja.

Manje važni kriteriji za donositelja odluke pri procjeni efikasnosti poslovanja banaka u ovom istraživanje su odnos kamatnih prihoda i kamatnih rashoda (6,43%) te neto kamatna marža (3,65%).

Provjera jesu li ocjene omjera važnosti donesene potpuno konzistentno vrši se izračunom indeksa CI i omjera CR konzistencije. Stupce matrice iz početne tablice 12 potrebno je pomnožiti sa odgovarajućim težinama. Rezultat je matrica prikazana tablicom 14. U dobivenoj tablici računa se suma svakog retka. Vrijednost λ dobije se kada se suma svakog retka prikazana u tablici 14 u predzadnjem stupcu podijeli sa prethodno dobivenim težinama. λ_{\max} računa se kao prosječna vrijednost veličina prikazanih u zadnjem stupcu tablice 14 i iznosi $\lambda_{\max}=6,257289$. Indeks konzistencije dobije se kao omjer razlike λ_{\max} i broja kriterija, te broj kriterija umanjen za jedan i iznosi $CI=0,0515$. Omjer konzistencije računa se kao omjer indeksa konzistencije i slučajnog indeksa RI prikazanog u tablici 9 koji iznosi 1,25. Omjer konzistencije je tada $CR=0,0412$. S obzirom da je $CR \leq 0,10$, procjena važnosti kriterija smatra se konzistentnom.

Tablica 14. Matrica i vrijednost λ

	C1	C2	C3	C4	C5	C6	Σ	λ
C1	0,36955	0,51282	0,219	0,45337	0,32153	0,47967	2,35594	6,375137
C2	0,18478	0,25641	0,219	0,34003	0,32153	0,31978	1,64152	6,401928
C3	0,06159	0,04274	0,0365	0,02834	0,02144	0,03198	0,22258	6,098003
C4	0,09239	0,08547	0,146	0,11334	0,19292	0,07994	0,71006	6,26469
C5	0,07391	0,05128	0,1095	0,03778	0,06431	0,0533	0,39007	6,065957
C6	0,12318	0,12821	0,1825	0,22669	0,19292	0,15989	1,01338	6,338018

Izvor: Izrada autorice

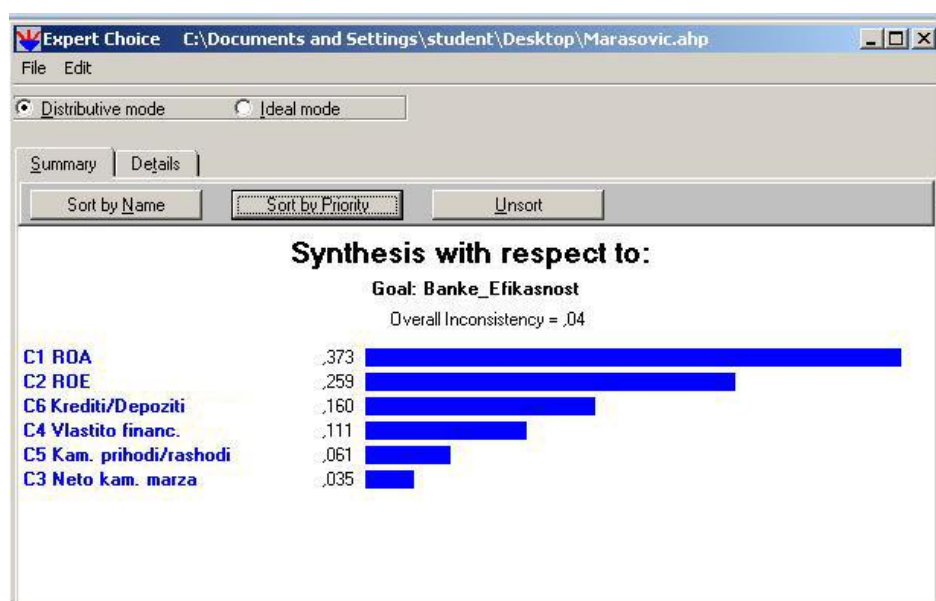
Osim aproksimativnim postupkom dobivene težine moguće je odrediti u softverskom paketu Expert Choice.

C1 ROA	C2 ROE	C3 Neto ka	C4 Vlastito	C5 Kam. pr	C6 Krediti/l
	2,0	6,0	4,0	5,0	3,0
		6,0	3,0	5,0	2,0
			4,0	3,0	5,0
				3,0	2,0
					3,0
Incon: 0,04					

Slika 8. Ulazni podatci u programu Expert Choice

Izvor: Izrada autorice

Slika 8 prikazuje dio matrice međusobnih usporedbi iznad glavne dijagonale. Crveni broj u matrici predstavlja inverznu vrijednost, tako se na primjer crveni broj 5 računa kao 1/5. Indeks konzistencije u programu Expert Choice jednak je prethodno izračunatom i također iznosi 0,04, što ukazuje da su procjene važnosti kriterija dane prilično konzistentno.



Slika 9. Težine kriterija dobivene programom Expert Choice

Izvor: Izrada autorice

Vrijednosti dobivene programom Expert Choice veoma su slične onima dobivenim aproksimativnim postupkom metodom svojstvenog vektora. Slika 9 prikazuje konačne vrijednosti težina poredane od najveće do najmanje. U nastavku rada za potrebe izračuna pojedinih metoda koristit će se težine dobivene aproksimativnim postupkom metodom svojstvenog vektora.

1.3. Rangiranje banaka TOPSIS metodom

Kod TOPSIS metode potrebno je pronaći najbolju banku koja je najmanje udaljena od idealne alternative i najviše udaljena od antiidealne alternative.

Prvi korak u primjeni TOPSIS metode je transformacija tablice odluke (Tablica 15.) vektorskom transformacijom, kako bi se dobila skala koja omogućava usporedbu među kriterijima. Vektorskom transformacijom se svaki stupac tablice odluke dijeli s normom tog stupca.

Tablica 15. Tablica odluke - banke

		Rentabilnost imovine (ROA)	Rentabilnost kapitala (ROE)	Neto kamatna marža	Koeficijent vlastitog financiranja	Odnos kamatnih prihoda i rashoda	Odnos danih kredita i primljenih depozita
BANKE		C1	C2	C3	C4	C5	C6
		max	max	max	max	max	min
A1	Addiko Bank d.d.	0,73	8,03	2,27	0,14	2,82	0,65
A2	Banka Kovanica d.d.	0,46	4,54	5,15	0,1	4,7	0,85
A3	Erste&Steiermärkische Bank d.d.	0,97	5,57	3,14	0,12	4,75	0,88
A4	Hrvatska poštanska banka d.d.	0,066	0,41	2,68	0,1	4,85	0,65
A5	Istarska kreditna banka Umag d.d.	0,95	8,85	2,21	0,09	3,95	0,53
A6	Karlovačka banka d.d.	0,35	5,42	2,37	0,06	3,07	0,58
A7	KentBank d.d.	0,25	2,27	2,89	0,11	3,55	0,7
A8	Kreditna banka Zagreb d.d.	0,75	6,17	2,36	0,1	2,61	0,77
A9	OTP banka Hrvatska d.d.	0,33	1,04	2,68	0,26	5,91	0,79
A10	Partner banka d.d.	0,46	3,51	2,43	0,11	2,79	0,67
A11	Podravska banka d.d.	0,53	3,22	2,33	0,13	3,21	0,7
A12	Privredna banka Zagreb d.d.	1,6	8,11	2,82	0,16	6,53	0,82
A13	Raiffeisenbank Austria d.d.	0,85	4,01	2,67	0,14	5,04	0,72
A14	Slatinska banka d.d.	0,08	0,39	2,57	0,1	2,82	0,61
A15	Zagrebačka banka d.d.	1,01	5,76	2,74	0,14	2,78	0,82
	W _j – težine	0,3696	0,2564	0,0365	0,1133	0,0643	0,1599

Izvor: Izrada autorice

U tablici 16. prikazani su kvadrati dobiveni kvadriranjem svakog elementa tablice odluke. U predzadnjem retku tablice je suma kvadrata svakog stupca potrebna za izračun norme stupca. Konačno se norma računa kao korijen iz sume kvadrata i vidljiva je u zadnjem retku tablice 16. Vrijednosti svakog elementa iz tablice odluke dijele se s navedenom normom pojedinog stupca kako bi se provela vektorska transformacija (Tablica 17).

Tablica 16. Suma kvadrata i norma stupca tablice odluke

BANKE		C1	C2	C3	C4	C5	C6
		max	max	max	max	max	min
A1	Addiko Bank d.d.	0,5329	64,4809	5,1529	0,0196	7,9524	0,4225
A2	Banka Kovanica d.d.	0,2116	20,6116	26,5225	0,01	22,09	0,7225
A3	Erste&Steiermärkische Bank d.d.	0,9409	31,0249	9,8596	0,0144	22,5625	0,7744
A4	Hrvatska poštanska banka d.d.	0,004356	0,1681	7,1824	0,01	23,5225	0,4225
A5	Istarska kreditna banka Umag d.d.	0,9025	78,3225	4,8841	0,0081	15,6025	0,2809
A6	Karlovačka banka d.d.	0,1225	29,3764	5,6169	0,0036	9,4249	0,3364
A7	KentBank d.d.	0,0625	5,1529	8,3521	0,0121	12,6025	0,49
A8	Kreditna banka Zagreb d.d.	0,5625	38,0689	5,5696	0,01	6,8121	0,5929
A9	OTP banka Hrvatska d.d.	0,1089	1,0816	7,1824	0,0676	34,9281	0,6241
A10	Partner banka d.d.	0,2116	12,3201	5,9049	0,0121	7,7841	0,4489
A11	Podravska banka d.d.	0,2809	10,3684	5,4289	0,0169	10,3041	0,49
A12	Privredna banka Zagreb d.d.	2,56	65,7721	7,9524	0,0256	42,6409	0,6724
A13	Raiffeisenbank Austria d.d.	0,7225	16,0801	7,1289	0,0196	25,4016	0,5184
A14	Slatinska banka d.d.	0,0064	0,1521	6,6049	0,01	7,9524	0,3721
A15	Zagrebačka banka d.d.	1,0201	33,1776	7,5076	0,0196	7,7284	0,6724
	Σ kvadrata	8,25016	406,158	120,85	0,2592	257,309	7,8404
	NORMA	2,872308	20,15337	10,99318	0,509117	16,04085	2,800071

Izvor: Izrada autorice

Iz transformirane tablice potrebno je odrediti idealnu i antiidealnu alternativu. Idealna alternativa je ona koja ima najbolje vrijednosti za svaki kriterij, tako je za benefit kriterije idealna banka sa maksimalnom vrijednosti kriterija, dok je za troškovne kriterije idealna ona sa minimalnom vrijednosti. Kod antiidealne alternative biraju se najgore vrijednosti za svaki

kriterij. Za benefit kriterije to su banke sa minimalnom vrijednosti kriterija, dok je kod troškovnih kriterija obratno te se biraju banke sa maksimalnom vrijednosti. Idealne i antiidealne alternative prikazane su tablici 17 kao i težine kriterija dobivene aproksimativnim postupkom metodom svojstvenog vektora, potrebne za izračun udaljenosti alternativa od idealnog i antiidealnog rješenja.

Tablica 17. Vektorska transformacija

BANKE		C1	C2	C3	C4	C5	C6
		max	max	max	max	max	min
A1	Addiko Bank d.d.	0,254151	0,398445	0,206492	0,274986	0,175801	0,232137
A2	Banka Kovanica d.d.	0,160150	0,225273	0,468472	0,196419	0,293002	0,303564
A3	Erste&Steiermärkische Bank d.d.	0,337707	0,276381	0,285632	0,235702	0,296119	0,314278
A4	Hrvatska poštanska banka d.d.	0,022978	0,020344	0,243787	0,196419	0,302353	0,232137
A5	Istarska kreditna banka Umag d.d.	0,330744	0,439133	0,201034	0,176777	0,246246	0,189281
A6	Karlovačka banka d.d.	0,121853	0,268938	0,215588	0,117851	0,191386	0,207138
A7	KentBank d.d.	0,087038	0,112636	0,262890	0,216060	0,221310	0,249994
A8	Kreditna banka Zagreb d.d.	0,261114	0,306152	0,214678	0,196419	0,162710	0,274993
A9	OTP banka Hrvatska d.d.	0,114890	0,051604	0,243787	0,510688	0,368434	0,282136
A10	Partner banka d.d.	0,160150	0,174164	0,221046	0,216060	0,173931	0,239280
A11	Podravska banka d.d.	0,184521	0,159775	0,211950	0,255344	0,200114	0,249994
A12	Privredna banka Zagreb d.d.	0,557043	0,402414	0,256523	0,314270	0,407086	0,292850
A13	Raiffeisenbank Austria d.d.	0,295929	0,198974	0,242878	0,274986	0,314198	0,257136
A14	Slatinska banka d.d.	0,027852	0,019352	0,233781	0,196419	0,175801	0,217852
A15	Zagrebačka banka d.d.	0,351634	0,285808	0,249245	0,274986	0,173307	0,292850
	A+	0,55704	0,43913	0,46847	0,51069	0,40709	0,18928
	A-	0,02298	0,01935	0,20103	0,11785	0,16271	0,31428
	Wj – težine	0,3696	0,2564	0,0365	0,1133	0,0643	0,1599

Izvor: Izrada autorice

Izračun udaljenosti svake alternative od idealne i antiidealne alternative prikazan je u sljedećim tablicama. Udaljenost alternativa od idealnog rješenja S_{i+} računa se kao umnožak težina svakog kriterija i razlike elemenata transformirane tablice dobivene vektorskom transformacijom i idealne alternative, prikazane u tablici 18. Zatim se dobivene vrijednosti kvadriraju, računa se njihova suma i konačno korijen iz sume je udaljenost alternativa od idealnog rješenja S_{i+} (Tablica 19).

Slično tome, udaljenost alternativa od negativnog idealnog rješenja S_i^- dobije se kao umnožak težina svakog kriterija i razlike elemenata transformirane tablice dobivene vektorskom transformacijom i antiidealne alternative, prikazane u tablici 20. Te iste vrijednosti se kvadriraju, računa im se suma i korijen iz sume je udaljenost alternativa od antiidealnog rješenja S_i^- (Tablica 21).

Tablica 18. Izračun udaljenosti od idealne alternative

BANKE		C1	C2	C3	C4	C5	C6
		max	max	max	max	max	min
A1	Addiko Bank d.d.	-0,11195	-0,01043	-0,00956	-0,02671	-0,01487	0,006853
A2	Banka Kovanica d.d.	-0,14669	-0,05483	0	-0,03561	-0,00734	0,018274
A3	Erste&Steiermärkische Bank d.d.	-0,08107	-0,04173	-0,00667	-0,03116	-0,00714	0,019987
A4	Hrvatska poštanska banka d.d.	-0,19739	-0,10738	-0,0082	-0,03561	-0,00673	0,006853
A5	Istarska kreditna banka Umag d.d.	-0,08364	0	-0,00976	-0,03783	-0,01034	0
A6	Karlovačka banka d.d.	-0,16085	-0,04364	-0,00923	-0,04451	-0,01387	0,002855
A7	KentBank d.d.	-0,17371	-0,08371	-0,0075	-0,03338	-0,01195	0,009708
A8	Kreditna banka Zagreb d.d.	-0,10938	-0,0341	-0,00926	-0,03561	-0,01571	0,013705
A9	OTP banka Hrvatska d.d.	-0,16342	-0,09936	-0,0082	0	-0,00249	0,014847
A10	Partner banka d.d.	-0,14669	-0,06794	-0,00903	-0,03338	-0,01499	0,007995
A11	Podravska banka d.d.	-0,13768	-0,07163	-0,00936	-0,02893	-0,01331	0,009708
A12	Privredna banka Zagreb d.d.	0	-0,00941	-0,00774	-0,02225	0	0,016561
A13	Raiffeisenbank Austria d.d.	-0,09651	-0,06158	-0,00823	-0,02671	-0,00597	0,01085
A14	Slatinska banka d.d.	-0,19559	-0,10763	-0,00857	-0,03561	-0,01487	0,004568
A15	Zagrebačka banka d.d.	-0,07592	-0,03931	-0,008	-0,02671	-0,01503	0,016561

Izvor: Izrada autorice

Tablica 19. Kvadrati

BANKE		C1	C2	C3	C4	C5	C6	Suma	S i +
		max	max	max	max	max	min		
A1	Addiko Bank d.d.	0,012533	0,000109	0,000091	0,000713	0,000221	0,000047	0,013714	0,117107
A2	Banka Kovanica d.d.	0,021518	0,003007	0,000000	0,001268	0,000054	0,000334	0,026181	0,161805
A3	Erste&Steiermärkische Bank d.d.	0,006572	0,001741	0,000045	0,000971	0,000051	0,000399	0,009779	0,098888
A4	Hrvatska poštanska banka d.d.	0,038963	0,011530	0,000067	0,001268	0,000045	0,000047	0,051920	0,227860
A5	Istarska kreditna banka Umag d.d.	0,006996	0,000000	0,000095	0,001431	0,000107	0,000000	0,008629	0,092893
A6	Karlovačka banka d.d.	0,025872	0,001904	0,000085	0,001981	0,000192	0,000008	0,030042	0,173328
A7	KentBank d.d.	0,030177	0,007008	0,000056	0,001114	0,000143	0,000094	0,038592	0,196449
A8	Kreditna banka Zagreb d.d.	0,011963	0,001163	0,000086	0,001268	0,000247	0,000188	0,014914	0,122123
A9	OTP banka Hrvatska d.d.	0,026706	0,009873	0,000067	0,000000	0,000006	0,000220	0,036873	0,192023
A10	Partner banka d.d.	0,021518	0,004616	0,000082	0,001114	0,000225	0,000064	0,027619	0,166188
A11	Podravska banka d.d.	0,018957	0,005130	0,000088	0,000837	0,000177	0,000094	0,025283	0,159008
A12	Privredna banka Zagreb d.d.	0,000000	0,000089	0,000060	0,000495	0,000000	0,000274	0,000918	0,030298
A13	Raiffeisenbank Austria d.d.	0,009314	0,003792	0,000068	0,000713	0,000036	0,000118	0,014040	0,118490
A14	Slatinska banka d.d.	0,038255	0,011585	0,000073	0,001268	0,000221	0,000021	0,051423	0,226766
A15	Zagrebačka banka d.d.	0,005764	0,001545	0,000064	0,000713	0,000226	0,000274	0,008587	0,092664

Izvor: Izrada autorice

Tablica 20. Izračun udaljenosti od antiidealne alternative

BANKE		C1	C2	C3	C4	C5	C6
		max	max	max	max	max	min
A1	Addiko Bank d.d.	0,085442	0,097199	0,000199	0,017803	0,000842	-0,01313
A2	Banka Kovanica d.d.	0,050699	0,052798	0,009762	0,008902	0,008378	-0,00171
A3	Erste&Steiermärkische Bank d.d.	0,116324	0,065902	0,003088	0,013353	0,008578	0
A4	Hrvatska poštanska banka d.d.	0	0,000254	0,001561	0,008902	0,008979	-0,01313
A5	Istarska kreditna banka Umag d.d.	0,11375	0,107632	0	0,006676	0,005371	-0,01999
A6	Karlovačka banka d.d.	0,036544	0,063994	0,000531	0	0,001844	-0,01713
A7	KentBank d.d.	0,023677	0,023918	0,002258	0,011127	0,003768	-0,01028
A8	Kreditna banka Zagreb d.d.	0,088015	0,073536	0,000498	0,008902	0	-0,00628
A9	OTP banka Hrvatska d.d.	0,033971	0,00827	0,001561	0,044508	0,013228	-0,00514
A10	Partner banka d.d.	0,050699	0,039694	0,00073	0,011127	0,000722	-0,01199
A11	Podravska banka d.d.	0,059706	0,036005	0,000398	0,015578	0,002405	-0,01028
A12	Privredna banka Zagreb d.d.	0,19739	0,098217	0,002025	0,022254	0,015713	-0,00343
A13	Raiffeisenbank Austria d.d.	0,100883	0,046055	0,001527	0,017803	0,009741	-0,00914
A14	Slatinska banka d.d.	0,001801	0	0,001195	0,008902	0,000842	-0,01542
A15	Zagrebačka banka d.d.	0,121471	0,06832	0,00176	0,017803	0,000681	-0,00343

Izvor: Izrada autorice

Tablica 21. Kvadrati

BANKE		C1	C2	C3	C4	C5	C6	Suma	Si -
		max	max	max	max	max	min		
A1	Addiko Bank d.d.	0,007300	0,009448	0,000000	0,000317	0,000001	0,000173	0,017238	0,131294
A2	Banka Kovanica d.d.	0,002570	0,002788	0,000095	0,000079	0,000070	0,000003	0,005606	0,074871
A3	Erste&Steiermärkische Bank d.d.	0,013531	0,004343	0,000010	0,000178	0,000074	0,000000	0,018136	0,134669
A4	Hrvatska poštanska banka d.d.	0,000000	0,000000	0,000002	0,000079	0,000081	0,000173	0,000335	0,018300
A5	Istarska kreditna banka Umag d.d.	0,012939	0,011585	0,000000	0,000045	0,000029	0,000399	0,024997	0,158103
A6	Karlovačka banka d.d.	0,001335	0,004095	0,000000	0,000000	0,000003	0,000293	0,005728	0,075683
A7	KentBank d.d.	0,000561	0,000572	0,000005	0,000124	0,000014	0,000106	0,001381	0,037168
A8	Kreditna banka Zagreb d.d.	0,007747	0,005407	0,000000	0,000079	0,000000	0,000039	0,013273	0,115209
A9	OTP banka Hrvatska d.d.	0,001154	0,000068	0,000002	0,001981	0,000175	0,000026	0,003407	0,058371
A10	Partner banka d.d.	0,002570	0,001576	0,000001	0,000124	0,000001	0,000144	0,004415	0,066443
A11	Podravska banka d.d.	0,003565	0,001296	0,000000	0,000243	0,000006	0,000106	0,005215	0,072218
A12	Privredna banka Zagreb d.d.	0,038963	0,009647	0,000004	0,000495	0,000247	0,000012	0,049368	0,222188
A13	Raiffeisenbank Austria d.d.	0,010177	0,002121	0,000002	0,000317	0,000095	0,000083	0,012796	0,113120
A14	Slatinska banka d.d.	0,000003	0,000000	0,000001	0,000079	0,000001	0,000238	0,000322	0,017954
A15	Zagrebačka banka d.d.	0,014755	0,004668	0,000003	0,000317	0,000000	0,000012	0,019755	0,140553

Izvor: Izrada autorice

Konačan rang banaka dobije se izračunom relativne bliskosti RC_i na način da se negativno idealno rješenja podijeli sa zbrojem idealnog i negativnog idealnog rješenja za svaku banku. Formula za izračun RC_i dana je relacijom (13). Banka je bolja ukoliko je RC_i bliže jedinici. Optimalan poredak banaka TOPSIS metodom prikazan je u tablici 22. Lako je zaključiti da je najbolja banka, prema ovoj metodi, Privredna banka Zagreb d.d., nakon čega slijede Istarska kreditna banka Umag, Zagrebačka banka, Erste&Steiermärkische Bank, Addiko Bank i dalje kako je prikazano u tablici.

Tablica 22. Izračun relativne bliskosti s idealnim rješenjem RC_i – konačan rang banaka prema TOPSIS metodi

A12	Privredna banka Zagreb d.d.	0,88
A5	Istarska kreditna banka Umag d.d.	0,629902
A15	Zagrebačka banka d.d.	0,60267
A3	Erste&Steiermärkische Bank d.d.	0,576601
A1	Addiko Bank d.d.	0,528557
A13	Raiffeisenbank Austria d.d.	0,488407
A8	Kreditna banka Zagreb d.d.	0,485435
A2	Banka Kovanica d.d.	0,316344
A11	Podravska banka d.d.	0,312326
A6	Karlovačka banka d.d.	0,303934
A10	Partner banka d.d.	0,285615
A9	OTP banka Hrvatska d.d.	0,233118
A7	KentBank d.d.	0,159097
A4	Hrvatska poštanska banka d.d.	0,07434
A14	Slatinska banka d.d.	0,073366

Izvor: Izrada autorice

1.4. Rangiranje banaka metodom jednostavnog zbrajanja težina – SAW

Kod ove metode prvo je potrebno formirati tablicu odluke (Tablica 23.) sa vrijednostima svih alternativa i pripadajućim kriterijima.

Tablica 23. Tablica odluke s numeričkim ocjenama - Banke

		Rentabilnost imovine (ROA)	Rentabilnost kapitala (ROE)	Neto kamatna marža	Koeficijent vlastitog financiranja	Odnos kamatnih prihoda i rashoda	Odnos danih kredita i primljenih depozita
BANKE		C1	C2	C3	C4	C5	C6
		max	max	max	max	max	min
A1	Addiko Bank d.d.	0,73	8,03	2,27	0,14	2,82	0,65
A2	Banka Kovanica d.d.	0,46	4,54	5,15	0,1	4,7	0,85
A3	Erste&Steiermärkische Bank d.d.	0,97	5,57	3,14	0,12	4,75	0,88
A4	Hrvatska poštanska banka d.d	0,066	0,41	2,68	0,1	4,85	0,65
A5	Istarska kreditna banka Umag d.d.	0,95	8,85	2,21	0,09	3,95	0,53
A6	Karlovačka banka d.d.	0,35	5,42	2,37	0,06	3,07	0,58
A7	KentBank d.d.	0,25	2,27	2,89	0,11	3,55	0,7
A8	Kreditna banka Zagreb d.d.	0,75	6,17	2,36	0,1	2,61	0,77
A9	OTP banka Hrvatska d.d.	0,33	1,04	2,68	0,26	5,91	0,79
A10	Partner banka d.d.	0,46	3,51	2,43	0,11	2,79	0,67
A11	Podravska banka d.d.	0,53	3,22	2,33	0,13	3,21	0,7
A12	Privredna banka Zagreb d.d.	1,6	8,11	2,82	0,16	6,53	0,82
A13	Raiffeisenbank Austria d.d.	0,85	4,01	2,67	0,14	5,04	0,72
A14	Slatinska banka d.d.	0,08	0,39	2,57	0,1	2,82	0,61
A15	Zagrebačka banka d.d.	1,01	5,76	2,74	0,14	2,78	0,82
	Wj – težine	0,3696	0,2564	0,0365	0,1133	0,0643	0,1599

Izvor: Izrada autorice

Kako bi se dobila usporediva skala za sve vrijednosti matrice, potrebno je primjenom linearne transformacije transformirati tablicu odluke, pazeći pritom na benefit i troškovne kriterije. Za benefit kriterije vrijedi pravilo da se svaki element odgovarajućeg kriterija dijeli sa maksimalnom vrijednošću tog kriterija, u ovom slučaju za kriterij rentabilnost imovine (ROA) svaki element u tom stupcu dijeli se sa maksimalnom vrijednošću 1,6. Kod troškovnog kriterija, u ovom primjeru odnos danih kredita i primljenih depozita, minimalna vrijednost 0,53 dijeli se sa svim elementima tog kriterija. Na ovaj način su svi kriteriji transformirani u benefit kriterije.

Transformiranoj tablici (Tablica 24.) pridružene su težine svakog kriterija prethodno izračunate metodom svojstvenog vektora.

Tablica 24. Linearna transformacija - banke

BANKE		C1	C2	C3	C4	C5	C6
		max	max	max	max	max	min
A1	Addiko Bank d.d.	0,45625	0,907345	0,440777	0,538462	0,431853	0,815385
A2	Banka Kovanica d.d.	0,2875	0,512994	1	0,384615	0,719755	0,623529
A3	Erste&Steiermärkische Bank d.d.	0,60625	0,629379	0,609709	0,461538	0,727412	0,602273
A4	Hrvatska poštanska banka d.d.	0,04125	0,046328	0,520388	0,384615	0,742726	0,815385
A5	Istarska kreditna banka Umag d.d.	0,59375	1	0,429126	0,346154	0,6049	1
A6	Karlovačka banka d.d.	0,21875	0,612429	0,460194	0,230769	0,470138	0,913793
A7	KentBank d.d.	0,15625	0,256497	0,561165	0,423077	0,543645	0,757143
A8	Kreditna banka Zagreb d.d.	0,46875	0,697175	0,458252	0,384615	0,399694	0,688312
A9	OTP banka Hrvatska d.d.	0,20625	0,117514	0,520388	1	0,905054	0,670886
A10	Partner banka d.d.	0,2875	0,39661	0,471845	0,423077	0,427259	0,791045
A11	Podravska banka d.d.	0,33125	0,363842	0,452427	0,5	0,491577	0,757143
A12	Privredna banka Zagreb d.d.	1	0,916384	0,547573	0,615385	1	0,646341
A13	Raiffeisenbank Austria d.d.	0,53125	0,453107	0,518447	0,538462	0,771822	0,736111
A14	Slatinska banka d.d.	0,05	0,044068	0,499029	0,384615	0,431853	0,868852
A15	Zagrebačka banka d.d.	0,63125	0,650847	0,532039	0,538462	0,425727	0,646341
Wj – težine		0,3696	0,2564	0,0365	0,1133	0,0643	0,1599

Izvor: Izrada autorice

Ponderirane vrijednosti svake alternative dobiju se množenjem elemenata iz transformirane tablice za svaku banku sa odgovarajućim težinama kriterija. Formula za izračun dana je relacijom (6). Prema metodi jednostavnog zbrajanja težina najbolja banka je A12 (Privredna banka Zagreb d.d.), zatim A5 (Istarska kreditna banka Umag d.d.), sljedeće su banke A1 (Addiko Bank d.d.), A15 (Zagrebačka banka d.d.), A3 (Erste&Steiermärkische Bank d.d.), i dalje redom kako je prikazano u tablici 25.

Tablica 25. Rangiranje banaka metodom jednostavnog zbrajanja težina

A12	Privredna banka Zagreb d.d.	0,86192
A5	Istarska kreditna banka Umag d.d.	0,729527
A1	Addiko Bank d.d.	0,636517
A15	Zagrebačka banka d.d.	0,611339
A3	Erste&Steiermärkische Bank d.d.	0,603065
A13	Raiffeisenbank Austria d.d.	0,55979
A8	Kreditna banka Zagreb d.d.	0,54807
A2	Banka Kovanica d.d.	0,463851
A6	Karlovačka banka d.d.	0,457166
A11	Podravska banka d.d.	0,441558
A10	Partner banka d.d.	0,427069
A9	OTP banka Hrvatska d.d.	0,404124
A7	KentBank d.d.	0,347957
A4	Hrvatska poštanska banka d.d.	0,267833
A14	Slatinska banka d.d.	0,258268

Izvor: Izrada autorice

1.5. Rangiranje banaka PROMETHEE metodom

Rangiranje alternativa temeljem ranije odabranih kriterija vrši se PROMETHEE metodom. Na početku metode potrebno je ispuniti tablicu odluke sa svim alternativama i pripadajućim kriterijima. Za svaku alternativu, svakom od kriterija potrebno je odrediti jednu od šest funkcija preferencija. Donositelj odluke bira jednu od funkcija za svaki kriterij zajedno sa odgovarajućim parametrima poput praga indiferencije (q), praga preferencije (p) te parametra (s) koji se nalazi između pragova indiferencije i preferencije. Tablica odluke prikazana je u tablici 26.

Tablica 26. Tablica odluke - banke

BANKE		C1 (%)	C2 (%)	C3 (%)	C4	C5	C6
		max	max	max	max	max	min
A1	Addiko Bank d.d.	0,73	8,03	2,27	0,14	2,82	0,65
A2	Banka Kovanica d.d.	0,46	4,54	5,15	0,1	4,7	0,85
A3	Erste&Steiermärkische Bank d.d.	0,97	5,57	3,14	0,12	4,75	0,88
A4	Hrvatska poštanska banka d.d.	0,066	0,41	2,68	0,1	4,85	0,65
A5	Istarska kreditna banka Umag d.d.	0,95	8,85	2,21	0,09	3,95	0,53
A6	Karlovačka banka d.d.	0,35	5,42	2,37	0,06	3,07	0,58
A7	KentBank d.d.	0,25	2,27	2,89	0,11	3,55	0,7
A8	Kreditna banka Zagreb d.d.	0,75	6,17	2,36	0,1	2,61	0,77
A9	OTP banka Hrvatska d.d.	0,33	1,04	2,68	0,26	5,91	0,79
A10	Partner banka d.d.	0,46	3,51	2,43	0,11	2,79	0,67
A11	Podravska banka d.d.	0,53	3,22	2,33	0,13	3,21	0,7
A12	Privredna banka Zagreb d.d.	1,6	8,11	2,82	0,16	6,53	0,82
A13	Raiffeisenbank Austria d.d.	0,85	4,01	2,67	0,14	5,04	0,72
A14	Slatinska banka d.d.	0,08	0,39	2,57	0,1	2,82	0,61
A15	Zagrebačka banka d.d.	1,01	5,76	2,74	0,14	2,78	0,82
W_j – težine		0,3696	0,2564	0,0365	0,1133	0,0643	0,1599
Tip fun. pref.		V	III	IV	II	V	VI
q		0,2	/	2,5	0,11	3	/
p		0,9	6	3	/	5	/
s		/	/	/	/	/	0,7

Izvor: Izrada autorice

Za rentabilnost imovine (ROA) odabran je kriterij s linearnom preferencijom i područjem indiferencije. To znači da je donositelj odluke indiferentan dok je razlika u rentabilnosti imovine između dvije banke ispod praga 0,2, a pri razlici većoj od 0,9 postoji situacija stroge preferencije. U području između pragova 0,2 i 0,9, preferencija donositelja odluke raste linearno.

Za rentabilnost kapitala (ROE) odabran je treći tip kriterija, odnosno kriterij s linearnom preferencijom za kojeg je potrebno odrediti samo parametar p . Prag preferencije u ovom slučaju iznosi $p=6$. Preferencija donositelja odluke raste linearno sve dok razlika u rentabilnosti kapitala dvije banke ne dosegne vrijednost 6, nakon toga postoji stroga preferencija.

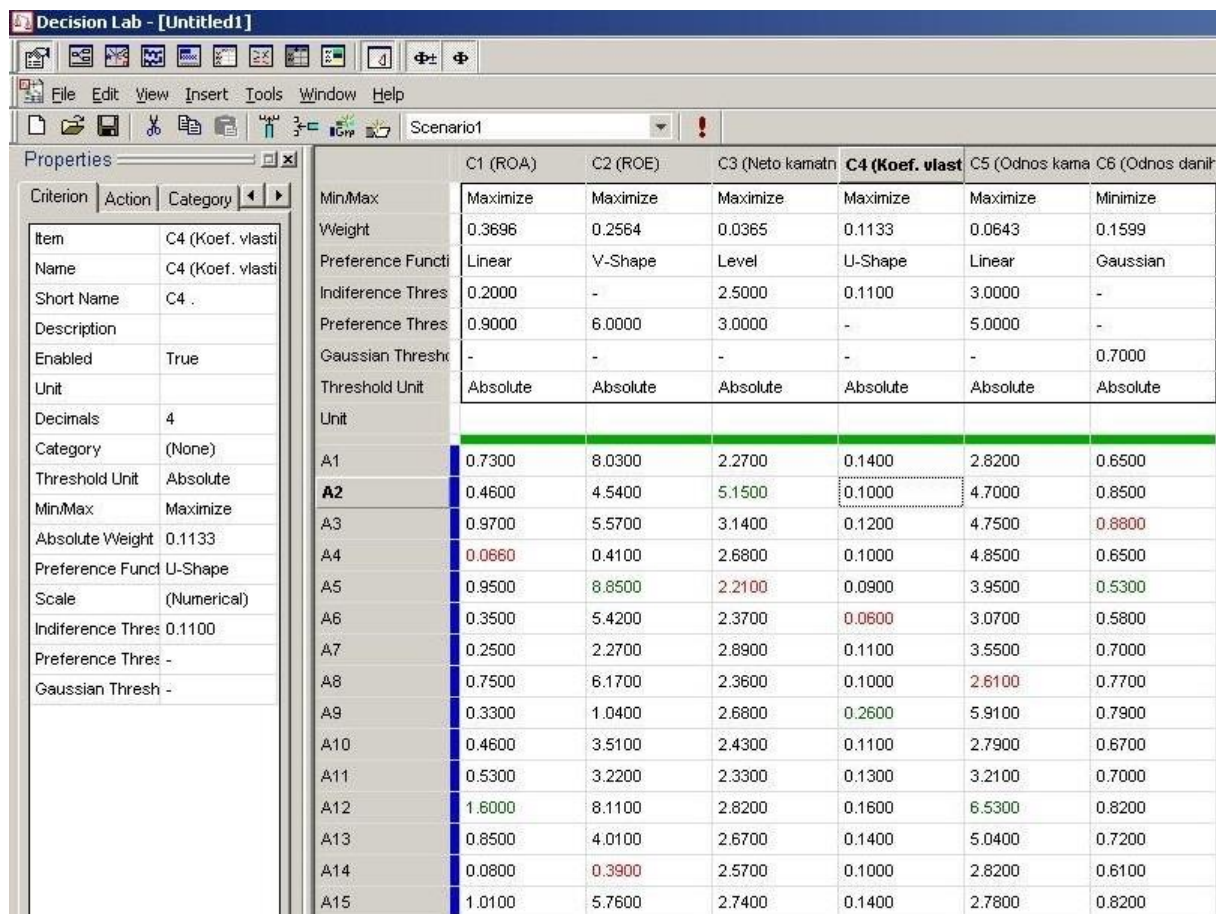
Nivo kriterij odabran je za neto kamatnu maržu. Vrijednosti pragova su $q=2,5$ i $p=3$. Donositelj odluke je indiferentan ukoliko je razlika u ocjenama između dvije banke manja od 2,5, dok za vrijednost veću od 3 postoji stroga preferencija. Kada se razlika u ocjenama alternativa nalazi između pragova indiferencije i preferencije, postoji slaba preferencija.

Kvazi kriterij, tip II, odabran je za koeficijent vlastitog financiranja kod kojeg su dvije banke za donositelja odluke indiferentne sve dok razlika njihovih ocjena ne prijeđe prag $q=0,11$. Kada razlika njihovih ocjena premaši 0,11, postoji stroga preferencija, odnosno vrijednost funkcije preferencije iznosi jedan.

Za odnos kamatnih prihoda i kamatnih rashoda odabran je kriterij s linearnom preferencijom i područjem indiferencije kao i kod rentabilnosti imovine. Vrijednosti praga indiferencije i preferencije iznose, $q=3$ i $p=5$.

Za odnos danih kredita i primljenih depozita odabran je Gaussov kriterij. Za ovu funkciju potrebno je samo definirati parametar s koji leži u području slabe preferencije i u ovom slučaju iznosi 0,7.

Metoda PROMETHEE u ovom radu rješavala se u programu Decision Lab. Ulazni podaci u programu Decision Lab prikazani su na slici 10. Alternative su prikazane oznakom od A1 do A15, dok su kriteriji označeni od C1 do C6, od kojih neke treba maksimizirati, a neke minimizirati. Korištene težine kriterija dobivene su metodom svojstvenog vektora čiji je izračun prikazan u prethodnom poglavlju.

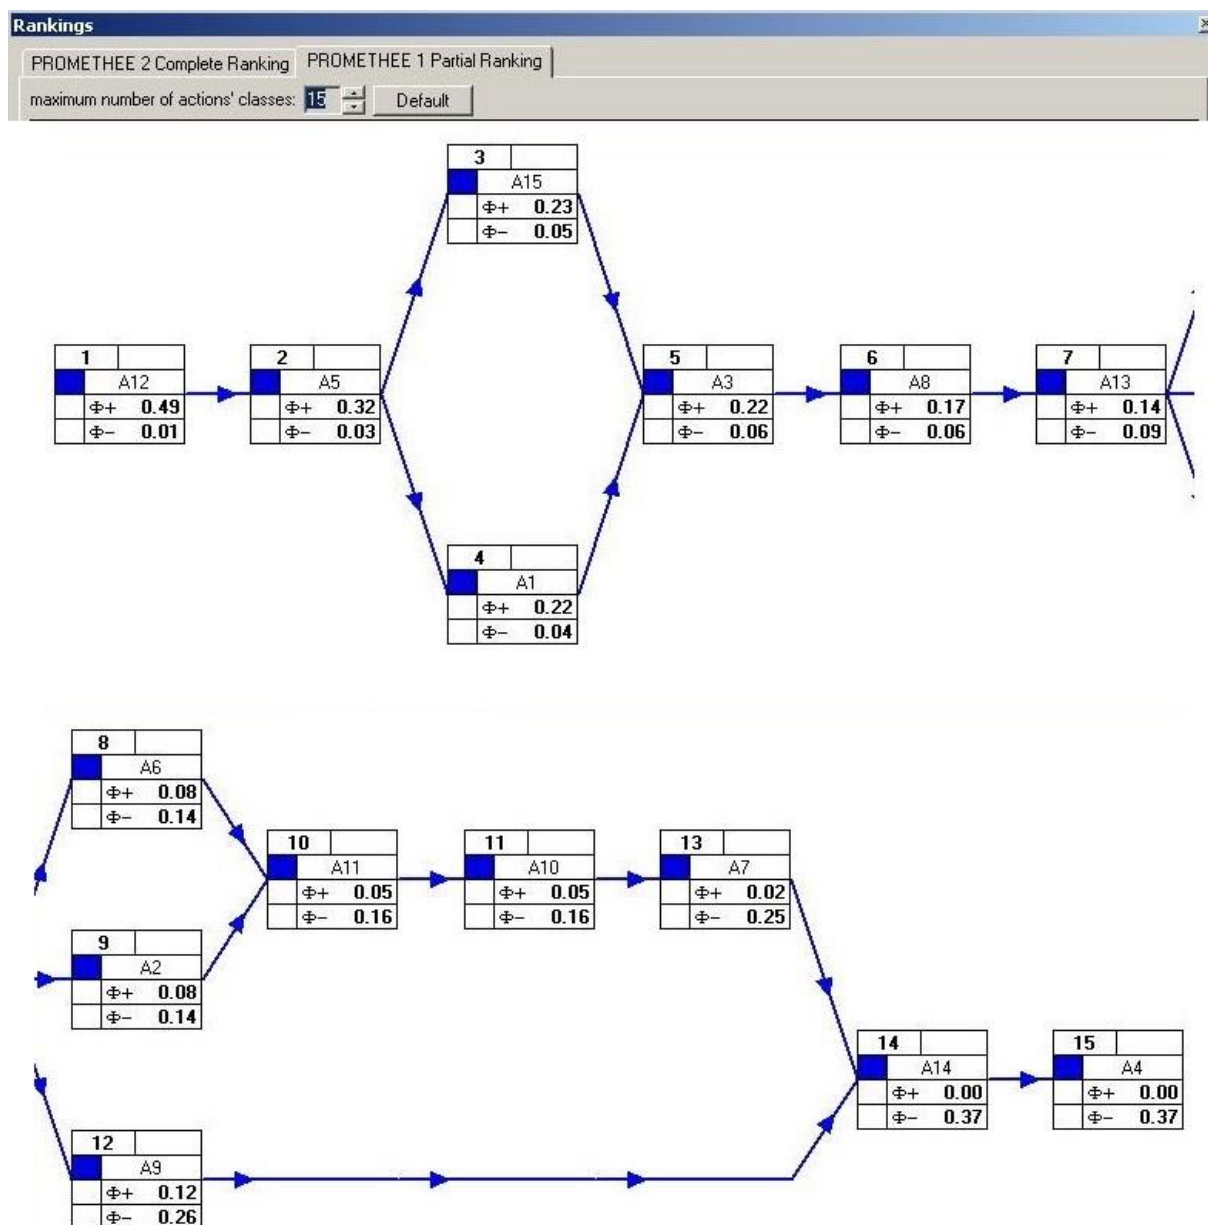


Properties		C1 (ROA)	C2 (ROE)	C3 (Neto kamata)	C4 (Koef. vlasti)	C5 (Odnos kama)	C6 (Odnos danir)
Criterion	Action	Maximize	Maximize	Maximize	Maximize	Maximize	Minimize
Item	C4 (Koef. vlasti)	0.3696	0.2564	0.0365	0.1133	0.0643	0.1599
Name	C4 (Koef. vlasti)	Linear	V-Shape	Level	U-Shape	Linear	Gaussian
Short Name	C4	0.2000	-	2.5000	0.1100	3.0000	-
Description		0.9000	6.0000	3.0000	-	5.0000	-
Enabled	True	-	-	-	-	-	0.7000
Unit		Absolute	Absolute	Absolute	Absolute	Absolute	Absolute
Decimals	4						
Category	(None)						
Threshold Unit	Absolute						
Min/Max	Maximize						
Absolute Weight	0.1133						
Preference Function	U-Shape						
Scale	(Numerical)						
Indifference Thres	0.1100						
Preference Thres	-						
Gaussian Thresh	-						
A1		0.7300	8.0300	2.2700	0.1400	2.8200	0.6500
A2		0.4600	4.5400	5.1500	0.1000	4.7000	0.8500
A3		0.9700	5.5700	3.1400	0.1200	4.7500	0.8800
A4		0.0660	0.4100	2.6800	0.1000	4.8500	0.6500
A5		0.9500	8.8500	2.2100	0.0900	3.9500	0.5300
A6		0.3500	5.4200	2.3700	0.0600	3.0700	0.5800
A7		0.2500	2.2700	2.8900	0.1100	3.5500	0.7000
A8		0.7500	6.1700	2.3600	0.1000	2.6100	0.7700
A9		0.3300	1.0400	2.6800	0.2600	5.9100	0.7900
A10		0.4600	3.5100	2.4300	0.1100	2.7900	0.6700
A11		0.5300	3.2200	2.3300	0.1300	3.2100	0.7000
A12		1.6000	8.1100	2.8200	0.1600	6.5300	0.8200
A13		0.8500	4.0100	2.6700	0.1400	5.0400	0.7200
A14		0.0800	0.3900	2.5700	0.1000	2.8200	0.6100
A15		1.0100	5.7600	2.7400	0.1400	2.7800	0.8200

Slika 10. Ulazni podatci za PROMETHEE metodu

Izvor: Izrada autorice u programu Decision Lab

Grafički prikaz parcijalnog uređaja PROMETHEE I dobiven programom Decision Lab prikazan je na slici 11.



Slika 11. PROMETHEE 1 – parcijalni uredaj

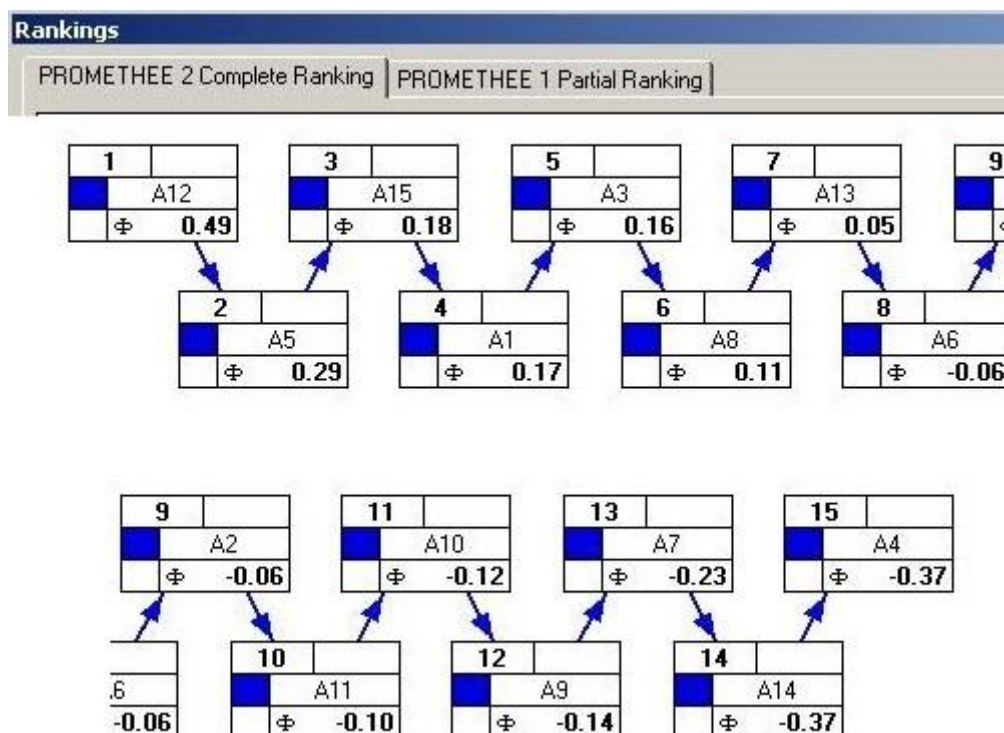
Izvor: Izrada autorice u softveru Decision Lab

Može se lako uočiti da je po pozitivnom i negativnom toku najbolja alternativa A12 (Privredna banka Zagreb d.d.), budući da ima najveći pozitivni tok 0,49, te najmanji negativni tok 0,01. Sljedeća najbolja alternativa je A5 (Istarska kreditna banka Umag d.d.), koja ima sljedeći najveći pozitivan tok 0,32, te drugi najmanji negativni tok 0,03.

Alternative A1 (Addiko Bank d.d.) i A15 (Zagrebačka banka d.d.) su međusobno neusporedive, s obzirom da alternativa A15 ima bolji pozitivni tok, ali je lošija po negativnom toku od alternative A1. Isto tako alternativa A9 (OTP banka Hrvatska d.d.) ne može se

uspoređivati s alternativama A6, A2, A11, A10, A7, jer je bolja po pozitivnom toku, ali lošija po negativnom toku.

Za potpuni poredak alternativa koristi se metoda PROMETHEE II koja rangira alternative od najbolje do najlošije. Ta metoda prikazuje neto tok svake alternative, odnosno razliku pozitivnog i negativnog toka i prikazana je na slici 12.



Slika 12. PROMETHEE II - kompletan uređaj

Izvor: Izrada autorice u programu Decision Lab

Iz konačnog poretka banaka dobivenih PROMETHEE II metodom može se vidjeti da je alternativa A12, odnosno Privredna banka Zagreb d.d. najbolja. Nakon toga slijede od najbolje do najgore redom A5 (Istarska kreditna banka Umag d.d.), A15 (Zagrebačka banka d.d.), A1 (Addiko Bank d.d.), A3 (Erste&Steiermärkische Bank d.d.), A8 (Kreditna banka Zagreb d.d.), A13 (Raiffeisenbank Austria d.d.), A6 (Karlovačka banka d.d.), A2 (Banka Kovanica d.d.), A11 (Podravska banka d.d.), A10 (Partner banka d.d.), A9 (OTP banka Hrvatska d.d.), A7 (Kentbank d.d.), A14 (Slatinska banka d.d.) i A4 (Hrvatska poštanska banka d.d.). Konačan poredak PROMETHEE II metodom prikazan je na slici 12.

Preference Flows			
	$\Phi+$	$\Phi-$	Φ
A1	0.2189	0.0448	0.1741
A2	0.0753	0.1375	-0.0622
A3	0.2165	0.0582	0.1582
A4	0.0023	0.3704	-0.3681
A5	0.3168	0.0264	0.2904
A6	0.0838	0.1412	-0.0574
A7	0.0163	0.2504	-0.2341
A8	0.1678	0.0615	0.1063
A9	0.1152	0.2573	-0.1420
A10	0.0474	0.1631	-0.1157
A11	0.0503	0.1551	-0.1049
A12	0.4947	0.0058	0.4889
A13	0.1420	0.0919	0.0501
A14	0.0035	0.3689	-0.3654
A15	0.2347	0.0531	0.1816

Slika 13. Pozitivan, negativan i neto tok

Izvor: Izrada autorice u programu Decision Lab

Iako je jednostavnije koristiti PROMETHEE II koji prikazuje kompletan poredak banaka, PROMETHEE I daje realnije rezultate koji su bitni prilikom donošenja konačne odluke.

Popis svih pozitivnih, negativnih tokova te neto toka vidi se iz gornje slike 13.

4.5. Komparacija rezultata dobivenih metodama višekriterijalnog odlučivanja

Primjenom gore navedenih metoda višekriterijalnog odlučivanja te njihovom interpretacijom uočljivo je kako su dobiveni rezultati slični. Rezultati dobiveni PROMETHEE i TOPSIS metodama prikazuju jednake rezultate za prve tri banke. Prema jednoj i drugoj metodi kao najbolja banka ističe se Privredna banka Zagreb, zatim Istarska kreditna banka Umag te Zagrebačka banka. Dalje se rezultati po metodama razlikuju, međutim ne odstupaju previše za neke banke. Tako su na primjer banke Erste&Steiermärkische Bank d.d. i Addiko Bank d.d. kod TOPSIS metode na četvrtom i petom mjestu, dok je kod PROMETHEE metode obratno, Addiko Bank d.d. zauzima četvrto dok je Erste&Steiermärkische Bank d.d. na petom mjestu. Isto je i za Raiffeisenbank Austria d.d. te Kreditnu banku Zagreb d.d. Raiffeisenbank Austria d.d. ima bolju poziciju kod TOPSIS metode te je na šestom mjestu, dok kod PROMETHEE metode zauzima sedmo mjesto. Kreditna banka Zagreb d.d. kod PROMETHEE metode zauzima šesto mjesto, a kod TOPSIS metode je na sedmom mjestu.

Rezultati dobiveni metodom jednostavnog zbrajanja težina također ističu Privrednu banku Zagreb kao najbolju alternativu te Istarsku kreditnu banku Umag rangira na drugo mjesto kao i prethodne dvije metode, međutim poredak ostalih banaka nešto se razlikuje. Erste&Steiermärkische Bank je na petom mjestu kao i kod PROMETHEE metode. Raiffeisenbank Austria d.d. i Kreditna banka Zagreb svrstane su na šesto i sedmo mjesto kao i kod TOPSIS metode.

Sve tri metode navode nekoliko istih banaka među prvih pet ali drugačijim redoslijedom. To su: A1 (Addiko Bank d.d.), A3 (Erste&Steiermärkische Bank d.d.), A5 (Istarska kreditna banka Umag d.d.), A12 (Privredna banka Zagreb d.d.) te A15 (Zagrebačka banka d.d.).

Kod sve tri metode najlošije rangirane banke su A9 (OTP banka Hrvatska d.d.), A7 (KentBank d.d.), A4 (Hrvatska poštanska banka d.d.) i A14 (Slatinska banka d.d.), te zauzimaju posljednje mjesto.

Rezultati dobiveni navedenim metodama su zadovoljavajući jer se uvelike podudaraju. Donositelju odluke olakšavaju proces donošenja odluke o najefikasnijoj banci, jer sve tri daju isti rezultat te navode Privrednu banku Zagreb kao najučinkovitiju. Također, prikazuju nekoliko istih banka među boljima, ali drugačijim poretkom.

6. ZAKLJUČAK

Kao i svaki drugi poslovni subjekti, banke posluju s ciljem ostvarivanja profita, uz što manji rizik. Na poslovanje banaka svakodnevno utječu razne promjene iz dinamičnog i izazovnog okruženja. Stoga moraju brzo donositi odluke i odgovoriti na promjene kako bi osigurale budući rast i razvoj, ostale konkurentne i opstale na tržištu. Učinkovito poslovanje banaka nije samo u interesu vlasnika, već i ostalih interesnih skupina, jer efikasno poslovanje banke utječe na stabilnost cjelokupnog financijskog sektora. Sa svrhom efikasnog upravljanja bankom i ostvarivanja njenih ciljeva menadžeri moraju donositi racionalne poslovne odluke na temelju kvalitetnih informacija. Informacije o ostvarenim rezultatima poslovanja banke sadržane su u financijskim izvještajima.

U procjeni učinkovitosti banaka najčešće se primjenjuje analiza financijskih pokazatelja. Nije moguće procijeniti efikasnost poslovanja banaka na temelju jednog pokazatelja, stoga se za preciznije rezultate razmatra istodobno nekoliko njih, koji mogu biti konfliktni. Taj problem rješava se metodama višekriterijalnog odlučivanja.

Efikasnost banaka može se gledati sa različitih aspekata, na temelju čega će se, ovisno o preferencijama donositelja odluke, odabrati odgovarajući pokazatelji. U ovom radu odabrano je šest kriterija iz četiri skupine pokazatelja profitabilnosti, likvidnosti, zaduženosti i ekonomičnosti. Naglasak je na pokazateljima profitabilnosti kao najčešćoj mjeri efikasnosti poslovanja banaka.

Cilj ovog rada je prikazati metodologiju izračuna višekriterijalne analize, te na osnovu dobivenih rezultata pomoći u procesu donošenja odluke o najefikasnijoj banci. Primjenom metoda višekriterijalnog odlučivanja rangiraju se banke po efikasnosti u namjeri da donositelju odluke olakšaju u izboru banke koja najučinkovitije posluje. Istraživanje se provelo na 15 banaka koje posluju na području Republike Hrvatske i imaju dostupne financijske izvještaje. U radu su korištene metoda jednostavnog zbrajanja težina, TOPSIS i PROMETHEE metode kojima su rangirane banke od najbolje do najgore. Procjena važnosti kriterija provedena je metodom svojstvenog vektora, a rezultati iste korišteni su za izračun gore navedenih metoda.

Sve tri korištene metode kao najbolju alternativu ističu Privrednu banku Zagreb. Rezultati dobiveni TOPSIS metodom i PROMETHEE metodom su slični, te imaju isti poredak za prve tri banke i to Privredna banka Zagreb, Istarska kreditna banka Umag te Zagrebačka banka. Ostale banke imaju nešto drugačiji poredak, ali ne odstupaju previše kod obje metode. Metoda jednostavnog zbrajanja težina ima nešto drugačiji poredak ali isto kao prethodne metode navodi Privrednu banku Zagreb i Istarsku kreditnu banku Umag među dvije najbolje. Sve tri metode navode nekoliko istih banaka među prvih pet ali drugačijim redoslijedom. Najbolje banke među prvih pet su: A1 (Addiko Bank d.d.), A3 (Erste&Steiermärkische Bank d.d.), A5 (Istarska kreditna banka Umag d.d.), A12 (Privredna banka Zagreb) te A15 (Zagrebačka banka).

Konačno, rezultati dobivenim navedenim metodama se prilično podudaraju. Donositelju odluke olakšavaju proces donošenja odluke o najefikasnijoj banci, jer sve tri navode istu, Privrednu banku Zagreb d.d. kao najefikasniju. Metodologija izračuna višekriterijalne analize prikazana u radu može poslužiti kao izvrstan alat u procjeni učinkovitosti poslovanja banaka, te na temelju analize i dobivenih rezultata pomoći u procesu donošenja konačne odluke.

LITERATURA

Knjige:

1. Babić, Z. (2010.): Linearno programiranje, Ekonomski fakultet, Split
2. Babić, Z. (2017): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet, Split
3. Ercegovac, R. (2016.): Teorija i praksa bankovnog menadžmenta, Sveučilište u Splitu, Ekonomski fakultet, Split
4. Gregurek, M., Vidaković, N. (2013.): Bankarsko poslovanje, drugo izdanje, Visoko učilište EFACTUS, Zagreb
5. Greuning, H. van, Brajović Bratanović, S. (2006.): Analiza i upravljanje bankovnim rizicima, MATE, Zagreb
6. Jakovčević, D. (2000.): Upravljanje kreditnim rizikom u suvremenom bankarstvu, TEB poslovno savjetovanje, Zagreb
7. Katunarić, A. (1988): Banka, principi i praksa bankovnog poslovanja, Zagreb
8. Leko, V. (2002.): Financijske institucije i tržišta I, Ekonomski fakultet, Zagreb
9. Mishkin, F., Eakins, S.G. (2005.): Financijska tržišta + institucije, IV izdanje, Mate, Zagreb
10. Nikolić, N., Pečarić, M. (2012.): Uvod u financije, Ekonomski fakultet Split
11. Rose, P. S. (2003.): Menadžment komercijalnih banaka, MATE, Zagreb
12. Rose, P. S., Hudgins, S. C. (2015.): Upravljanje bankama i financijske usluge, MATE d.o.o., Zagreb
13. Spero, H. (1953.): Money and banking, Barnes&Noble
14. Šverko, I. (2007.): Upravljanje nekreditnim rizicima u hrvatskim financijskim institucijama, Hrvatski institut za bankarstvo i osiguranje
15. Vidučić, LJ., Pepur, S., Šimić Šarić, M. (2015): Financijski menadžment, IX. Izdanje, RRif plus
16. Vujević, I. (2005.): Financijska analiza u teoriji i praksi, Ekonomski fakultet, Split
17. Zelenika, R. (2000.): Metodologija i tehnologija izrade znanstvenog i stručnog djela
18. Žager, K., Mamić Sačer, I., Sever, S., Žager, L. (2008.): Analiza financijskih izvještaja, MASMEDIA, Zagreb
19. Žager, K., Žager, L. (1999.): Analiza financijskih izvješća, MASMEDIA, Zagreb
20. Živko, I., Kandžija, V. (2014.): Upravljanje bankama, Ekonomski fakultet Sveučilišta, Mostar - Rijeka

Časopisi:

1. Babić, Z., Belak, V., Plazibat, N.: Ranking of Croatian banks according to business efficiency, Proceedings of the 5th International Symposium on Operational Research, Preddvor, Slovenija, 1999., str. 105-111
2. Kundid, A.: Indikatori profitabilnosti bankovnog poslovanja, Računovodstveno-financijske informacije, broj 12/2010; str. 17- 26
3. Kundid, A., Škrabić, B., Ercegovac, R.: Determinants of bank profitability in Croatia, Croatian Operational Research Review (CRORR), Vol. 2, 2011., str. 168-182
4. Pavković, A.: Instrumenti vrednovanja uspješnosti poslovnih banaka, Zbornik Ekonomskog fakulteta u Zagrebu, godina 2, broj 1, 2004., str. 179-192
5. Pejić Bach, M., Posedel, P., Stojanović, A.: Determinante profitabilnosti banaka u Hrvatskoj, Zbornik Ekonomskog fakulteta u Zagrebu, godina 7, broj 1., 2009., str. 81-92
6. Prga, I., Vrdoljak, T., Šverko, I.: Upravljanje rizikom likvidnosti korištenjem valutnih swap ugovora, 2009., str. 364-371
7. Prga, I., Šverko, I.: Izloženost banaka tržišnim rizicima, Zbornik Ekonomskog fakulteta u Zagrebu, godina 3, 2005., pregledni znanstveni članak 336.71:336.76
8. Tuškan, B., Stojanović, A.: Measurement of cost efficiency in the European banking industry, CRORR 7 (2016.), str 47-66
9. Vojvodić Rosenzweig, V., Volarević, H., Varović, M. (2011): A Goal Programming Approach to Ranking Banks, Proceedings of 11th International Conference on Operational Research, SOR. 2011., Slovenija, str. 149-156
10. Vučković, M.: Analiza učinkovitosti hrvatskih banaka pomoću višekriterijskog programiranja, EFZG, Serija članaka u nastajanju, članak broj 10-07
11. Zopounidis, C., Doumpos, M.: Multi-criteria decision aid in financial decision making: Methodologies and literature review, Journal of multi-criteria decision analysis, 2002., str. 167-186
12. Živko, I.: Kamatni rizik u bankarstvu – izvori i učinci, Ekonomska misao i praksa Dubrovnik, god XV (2006.), br. 2, str. 199-214

Izvori s Interneta:

1. Addiko Bank - <https://www.addiko.hr/>
2. Banka kovanica - <https://www.kovanica.hr/>
3. Erste&Steiermärkische Bank - <https://www.erstebank.hr/>
4. Hrvatska narodna banka - <https://www.hnb.hr/>
5. Hrvatska poštanska banka - <https://www.hpb.hr/>
6. Istarska kreditna banka Umag - <http://www.ikb.hr/>
7. Karlovačka banka - <http://www.kaba.hr/>
8. Kent Bank - <http://www.kentbank.hr/>
9. Kreditna banka Zagreb - <http://www1.kbz.hr/kreditna-banka-zagreb>
10. OTP banka - <https://www.otpbanka.hr/>
11. Partner banka - <http://www.paba.hr/>
12. Podravska banka - <https://www.poba.hr/>
13. Poslovni dnevnik - <http://www.poslovni.hr/>
14. Privredna banka Zagreb - <https://www.pbz.hr/>
15. Raiffeisenbank Austria - <https://www.rba.hr/>
16. Slatinska banka - <https://www.slatinska-banka.hr/>
17. Zagrebačka banka - <https://www.zaba.hr/home/>
18. Zagrebačka burza - <https://www.zse.hr/>
19. Zakon o računovodstvu, NN (120/16) - <https://www.zakon.hr/z/118/Zakon-o-ra%C4%8Dunovodstvu>

POPIS TABLICA:

Tablica 1. Pokazatelji likvidnosti banke	27
Tablica 2. Pokazatelji zaduženosti banke.....	28
Tablica 3. Pokazatelji ekonomičnosti.....	29
Tablica 4. Pokazatelji nekamatnih aktivnosti banke	29
Tablica 5. Pokazatelji rentabilnosti	30
Tablica 6. Pokazatelji marže i prosječnih kamatnih stopa	31
Tablica 7. Pokazatelji investiranja	32
Tablica 8. Saatyeva skala važnosti	34
Tablica 9. Slučajni indeks RI	35
Tablica 10. PROMETHEE I – parcijalni uređaj	45
Tablica 11. Banke i financijski pokazatelji	47
Tablica 12. Matrica međusobnih usporedbi	49
Tablica 13. Transformirana matrica i težine kriterija.....	50
Tablica 14. Matrica i vrijednost λ	51
Tablica 15. Tablica odluke - banke	53
Tablica 16. Suma kvadrata i norma stupca tablice odluke	54
Tablica 17. Vektorska transformacija	55
Tablica 18. Izračun udaljenosti od idealne alternative	56
Tablica 19. Kvadrati	56
Tablica 20. Izračun udaljenosti od antiidealne alternative	57
Tablica 21. Kvadrati	57
Tablica 22. Izračun relativne bliskosti s idealnim rješenjem RC_i – konačan rang banaka prema TOPSIS metodi	58
Tablica 23. Tablica odluke s numeričkim ocjenama - Banke	59
Tablica 24. Linearna transformacija - banke.....	60
Tablica 25. Rangiranje banaka metodom jednostavnog zbrajanja težina	61
Tablica 26. Tablica odluke - banke	62

POPIS SLIKA:

Slika 1. Obični kriterij	41
Slika 2. Kvazi kriterij	41
Slika 3. Kriterij s linearnom preferencijom.....	42
Slika 4. Nivo kriterij.....	42
Slika 5. Kriterij s linearnom preferencijom i područjem indifferencije	43
Slika 6. Gaussov kriterij	43
Slika 7. Lukovi $\Pi(a,b)$ i $\Pi(b,a)$	44
Slika 8. Ulazni podatci u programu Expert Choice.....	52
Slika 9. Težine kriterija dobivene programom Expert Choice	52
Slika 10. Ulazni podatci za PROMETHEE metodu.....	64
Slika 11. PROMETHEE 1 – parcijalni uređaj.....	65
Slika 12. PROMETHEE II - kompletan uređaj.....	66
Slika 13. Pozitivan, negativan i neto tok	67

SAŽETAK

S obzirom da banke posluju u dinamičnoj i neizvjesnoj okolini, analiza učinkovitosti poslovanja ključna je kako bi osigurale opstanak na tržištu. Kroz ovaj rad analizirana je poslovna učinkovitost banaka i izvršen izbor najefikasnije banke primjenom metoda višekriterijalnog odlučivanja na temelju izabranih kriterija. Banke su se uspoređivale primjenjujući kriterije rentabilnosti imovine (ROA), rentabilnosti kapitala (ROE), koeficijenta vlastitog financiranja, neto kamatne marže, odnosa kamatnih prihoda i rashoda te odnosa danih kredita i primljenih depozita. Cilj ovog rada je prikazati metodologiju izračuna višekriterijalne analize, te na temelju dobivenih rezultata pomoći u procesu donošenja odluke o najefikasnijoj banci. Rangiranje banaka od najbolje do najgore izvršeno je pomoću tri metode višekriterijalnog odlučivanja i to TOPSIS metode, PROMETHEE metode i metode jednostavnog zbrajanja težina. Rezultati dobiveni navedenim metodama su zadovoljavajući s obzirom da se uvelike podudaraju, jer sve tri metode kao najbolju alternativu ističu Privrednu banku Zagreb. Metodologija izračuna višekriterijalne analize prikazana u radu može poslužiti kao izvrstan alat u procjeni efikasnosti poslovanja banaka, te na temelju dobivenih rezultata pomoći u procesu donošenja konačne odluke.

Ključne riječi: BANKE, VIŠEKRITERIJALNO ODLUČIVANJE, PROCJENA
EFIKASNOSTI

SUMMARY

Banks operate in a dynamic and uncertain environment. Performance analysis is key to ensure market survival. Through this paper, business efficiency of banks was analyzed and a selection of the most efficient bank was carried out using the multicriteria decision making methods based on the selected criteria. Banks were compared using the Return on Assets (ROA), Return on Equity (ROE), self financing ratio, the net interest margin, the ratio of interest income and expense and loan to deposit ratio. The aim of this paper is to illustrate the methodology for calculating the multicriteria analysis and based on the obtained results help in decision making process. Banks are ranked, from best to worst, using the three methods of multicriterial decision making, TOPSIS method, PROMETHEE method and simple additive weighting method. Results obtained by these methods match significantly, since all three methods, point out Privredna banka Zagreb, as the best alternative. The methodology for calculating multicriteria analysis presented in this paper can be excellent tool to use when assessing banks efficiency, and based on the obtained results can help in decision making process.

Key words: BANKS, MULTICRITERIA DECISION MAKING, EFFICIENCY ESTIMATION